

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Anže Pečar

**Avtomatska detekcija pronacije in
supinacije tekačev s pomočjo
računalniškega vida**

DIPLOMSKO DELO
NA UNIVERZITETNEM ŠTUDIJSKEM PROGRAMU
RAČUNALNIŠTVA IN INFORMATIKE

MENTOR: doc. dr. Peter Peer

ASISTENT: mag. Jure Kovač

Ljubljana, 2014

Rezultati diplomskega dela so intelektualna lastnina avtorja in Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavljane ali izkoriščanje rezultatov diplomskega dela je potrebno pisno soglasje avtorja, Fakultete za računalništvo in informatiko ter mentorja.

Besedilo je oblikovano z urejevalnikom besedil \LaTeX .

Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Tematika naloge:

Preučite področje avtomatske detekcije pronacije in supinacije tekačev. Predlagajte rešitev za detekcijo na osnovi računalniškega vida, ki bo merila kot v gležnju na posnetkih tekačev med tekom na tekoči preprogi. Zajemite ustrezne testne podatke. Ovrednotite predlagano rešitev.

IZJAVA O AVTORSTVU DIPLOMSKEGA DELA

Spodaj podpisani Anže Pečar, z vpisno številko **63050071**, sem avtor diplomskega dela z naslovom:

*Avtomatska detekcija pronacije in supinacije tekačev
s pomočjo računalniškega vida*

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelal samostojno pod mentorstvom doc. dr. Petra Peera in mag. Jureta Kovača,
- so elektronska oblika diplomskega dela, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko diplomskega dela,
- soglašam z javno objavo elektronske oblike diplomskega dela v zbirki "Dela FRI".

V Ljubljani, 15. junija 2014

Podpis avtorja:

Zahvaljujem se mentorju dr. Petru Peeru in mag. Juretu Kovaču za potrpežljivost in pomoč pri izdelavi diplomske naloge.

Zahvaljujem se tudi Fakulteti za Šport in še posebej dr. Alešu Dolencu za vso strokovno pomoč pri izdelavi diplomske naloge ter za razpoložljive naprave in laboratorije, ki so jih nesebično ponudili na razpolago za snemanje. Zahvaljujem se tudi moji družini in prijateljem za vso izkazano podporo in pomoč.

Kazalo

Povzetek

Abstract

1	Uvod	1
2	Predstavitev problema	5
2.1	Športni vidik	5
2.2	Komercialni vidik	8
2.3	Vidik računalniškega vida	10
2.4	Motivacija in cilji	12
3	Predlagana rešitev	13
3.1	Uporabljeni algoritmi	13
3.2	Detekcija ospredja	15
3.3	Morfološke operacije	17
3.4	Določanje skeleta	20
3.5	Določanje točke gležnja	26
3.6	Obdelava signalov	28
3.7	Določanje faze opore	31
4	Zajem testnih podatkov	35
4.1	Poizkusno snemanje	35
4.2	Finalno snemanje	36

KAZALO

5	Rezultati in analiza	43
5.1	Ročno izmerjeni rezultati kota v gležnju	43
5.2	Avtomatska analiza	43
5.3	Klasifikacija tekačev in napačne klasifikacije	46
5.4	Diskusija	49
6	Sklepne ugotovitve	55
	Seznam slik	57
	Seznam tabel	59
	Literatura	61

Seznam uporabljenih kratic in simbolov

CVST – computer vision system toolbox

GMM – Gaussain mixture models

DFT – diskretna Fourierjeva transformacija

NaN – not a number

Povzetek

Tek je dandanes vse bolj popularna oblika rekreacije. Zato so vse pogostejši tudi tekaška društva in trgovine, ki ponujajo storitve, povezane z videoanalizo teka. Najbolj običajna storitev je ugotavljanje, ali je tekač pronator, supinator ali nevtralen tekač. Ena izmed metod za ugotavljanje tega je merjenje kota v gležnju. Ta se danes večinoma izvaja ročno na posnetkih tekača s hrbtne strani, medtem ko teče po tekoči preprogi. Zato obstaja potreba po razvoju aplikacij in algoritmov za avtomatsko računalniško analizo teka.

V tem diplomskem delu smo razvili in predstavili metode in algoritme za avtomatsko merjenje kota v gležnju na posnetkih tekačev med tekom na tekoči preprogi. Razviti algoritmi in metode avtomatsko izmerijo kot v gležnju in določijo, ali je tekač pronator, supinator ali nevtralen tekač. Uporabljene metode so se v primerjavi z ročnimi meritvami na majhni testni skupini 15 tekačev izkazale za primerno natančne za grobo klasifikacijo tekačev, vendar so za širšo komercialno rabo in uporabo v raziskavah v športu še premalo robustne in natančne. V sklopu tega dela zato podajamo tudi nekatere smernice za nadaljnje delo. Z njimi lahko odpravimo trenutne pomanjkljivosti in omogočimo učinkovitejšo rabo v praktičnih aplikacijah, ki imajo tako ekonomski potencial v splošni populaciji in trgovinah s športno opremo kot tudi potencial za uporabo v raziskavah na področju teka v športu.

Ključne besede:

analiza koraka, tek, detekcija gibanja, človeški skelet, avtomatska videoanaliza, računalniški vid

Abstract

Running is nowadays one of the most popular forms of recreation. Running societies, clubs and sport shops, which provide services related to video analysis of running, are, therefore, becoming more common. The most usual service they provide is determining whether a runner is a pronator, a supinator or a neutral runner. One of the methods for determining the pronation type is measuring the eversion angle of an ankle. The angle is usually measured manually from a backside video of a runner running on a treadmill. Therefore, there is a need to develop applications and algorithms for automatic analysis of running gait.

In this thesis we have developed and introduced methods and algorithms for automatic measurement of the eversion angle of an ankle on videos of runners on a treadmill. The algorithms and methods developed in this thesis automatically measure the eversion angle and determine the type of pronation. Tested on a small group of 15 runners, these methods turned out to be reasonably accurate for a rough classification of the pronation type in comparison with the manual method. They are, however, not robust and accurate enough for wider commercial use and for the purposes of research in sports. Therefore, we propose some guidelines and improvements for further work to eliminate current shortcomings and enable a more efficient use in practical applications, which have high economic potential for general population and can also be used in research.

Key words:

gait analysis, running, motion detection, human skeleton, automated video analysis, computer vision


Poglavje 1

Uvod

Tek je poleg hoje ena izmed najbolj naravnih oblik človeškega gibanja. Zaradi tega postaja dandanes del vsakdana vedno večjega števila ljudi. Človek teče že praktično od pradavnine, po letu 1980 pa je tek doživel velik razmah, sprva v Združenih državah Amerike, nato pa tudi v Evropi. Zaradi preprostosti te oblike rekreacije in spričo dejstva, da za tek ne potrebujemo veliko drage opreme in zanj ni posebnih prostorskih zahtev, se z njim ukvarja vedno več ljudi [1].

Tako kot vsak šport ima tudi tek svoje zakonitosti in svojo tehniko. Korak pri teku lahko razdelimo na dve fazi [2, 4]. Faza opore (angl. stance phase) je čas, ko je vsaj ena izmed nog v stiku s tlemi, druga faza je faza leta (angl. swing phase), ko je tekač z obema nogama v zraku (glej sliko 1.1). Fazo opore lahko nato delimo naprej na tri podfaze. Fazo dotika stopala s podlago (angl. initial contact), to je čas od takrat, ko se stopalo dotakne podlage, do popolne opore stopala. To je faza, v kateri pride do največjega sunka sile podlage in začetnega stika noge tekača s podlago (glej sliko 1.1). Sledi ji faza prenosa teže na celotno stopalo, tako imenovana faza srednjega opiranja (angl. midsupport); v tej fazi se teža tekača razporedi čez celotno stopalo in traja od začetka polne opore stopala do začetka plantarne fleksije v gležnju. Sledi ji faza odziva (angl. take off), ko se teža tekača prenese na prednji del stopala in potem na prste, sila se poveča, nato pa se noga

dvigne od podlage. Traja od začetka plantarne fleksije gležnja do trenutka, ko stopalo zapusti podlago. Tudi fazo leta delimo naprej na tri podfaze. Prva je začetna faza leta (angl. initial swing), začne se s koncem odriva in traja do največje iztegnitve noge v kolku; ta podfaza je zelo kratka. Druga podfaza je osrednja faza leta (angl. mid-swing), traja od trenutka največje iztegnitve noge v kolku do trenutka največje upognitve noge v kolku, torej do zaključka zamaha zamašne noge. Tretja podfaza, ki je priprava na dotik s podlago (angl. terminal swing), se konča z dotikom stopala s podlago. Pri teku si torej izmenično sledita faza opore in faza leta.



Slika 1.1: Prikaz vseh podfaz teka [3].

Ker se s tekom ukvarja vedno več ljudi, je ta postal tudi komercialno zanimiv in vedno več posameznikov, društev in podjetij ponuja storitve, povezane z njim. Ena izmed takšnih je tudi analiza teka.

Analiza teka je proces, v katerem se opazuje in analizira osnovno tekaško tehniko posameznika ter določi ključne napake, ki lahko vplivajo na preveliko izgubo energije ali so celo vzrok za morebitne poškodbe. Analiza se po navadi izvaja ročno. Postopek zajema snemanje tekača, običajno iz treh zornih kotov, s sprednje strani, z leve ali desne strani in od zadaj. Pri vsakem posnetku se nato analizira določene segmente [4].


Pri posnetku od zadaj se predvsem opazuje kot v gležnju, ki je pomemben za določanje, ali tekač morebiti pretirano zvrta nogo navzven ali navznoter. Ta kot določa tudi tip tekača glede na stopnjo pronacije [5]. Pronacija je naravno gibanje stopala pri stiku s podlago. Stik stopala s podlago je odvisen

od hitrosti teka in same tehnike tekača. Pri večini tekačev se podlage najprej dotakne peta, še zlasti pri počasnejšem teku, srednji ali prednji del stopala pa pri hitrejšem teku [1]. Po stiku s podlago se teža telesa preko stopala prenaša naprej proti prstom in pa z zunanje strani proti notranji strani stopala. Gibanje, ko se stopalo nagiba preko vzdolžne osi, imenujemo pronacija in je eden izmed mehanizmov, s katerimi človek ublaži sile, ki delujejo na telo pri stiku noge s podlago (glej sliko 1.2). Določena stopnja pronacije je tako zaželena in tudi potrebna, če pa se zvrčanje noge navznoter ne ustavi in se noga pretirano zvrne, govorimo o pretirani pronaciji. Take tekače imenujemo pronatorji. Nasprotno pa, če se noga premalo zvrne navznoter in ostane na zunanjem robu, govorimo o tako imenovani supinaciji; v angleščini se uporablja tudi izraz premajhna pronacija (angl. under-pronation) (glej sliko 1.2). V tem primeru se sile na tekača ne ublažijo dovolj. Take tekače imenujemo supinatorji [5]. Najbolj zaželena je torej ravno pravšnja stopnja pronacije in s tem optimalno blaženje sil, take tekače imenujemo nevtralni tekači. Varne stopnje pronacije so prikazane na sliki 1.2.

Podobno analizo izvajajo tudi v številnih športnih trgovinah. Proizvajalci športnih copat so razvili posebne športne copate, ki so primerne za pronatorje, supinatorje in tudi nevtralne tekače. Copate se med seboj razlikujejo. Pronatorji potrebujejo bolj stabilne športne copate, supinatorji mehkejše, ki bolj blažijo sile, nevtralni tekači pa imajo lahko lažje copate, saj ne potrebujejo posebnih dodatnih elementov, ki bi zagotavljali stabilnost ali blaženje.

Ker se podobne analize izvajajo v večji meri ročno, brez posebnih pomagala, je analiza, še posebej večjega števila tekačev, časovno zahtevna in podvržena tudi določeni stopnji človeških napak. Iz tega izvira potreba, da bi podobne analize računalniško avtomatizirali.

V nadaljevanju bomo najprej v poglavju 2 definirali različne vidike problema analize teka in ugotovili motivacijo za računalniško rešitev tega in podobnih problemov. Nato bomo v poglavju 3 pregledali naše ideje in pristope k reševanju tega problema ter opisali pomembnejše algoritme, ki smo jih uporabili za našo rešitev detekcije pronacije pri tekačih. V poglavju 4



Copyright 2010  **BodyScientific**
INTERNATIONAL

Slika 1.2: Prikaz pronacije, supinacije in nevtralnega položaja desne noge [6].

bomo podrobneje opisali izveden eksperiment. V poglavju 5 bomo primerjali uspešnost in natančnost algoritma v primerjavi z ročno analizo in v poglavju 6 podali možne izboljšave in smernice za nadaljnji razvoj.

Poglavje 2

Predstavitev problema

Rešitev problema vidimo v izdelavi algoritma za avtomatsko zaznavanje pronacije oziroma supinacije pri tekačih iz videoposnetka tekača, posnetega na elektronski tekaški preprogi (angl. treadmill). Aplikacija izmeri kot v gležnju in na podlagi tega določi, kakšne copate potrebuje tekač.

V nadaljevanju bomo predstavili tri vidike tega problema. Prvi vidik je športni vidik: kakšen je problem z vidika športnih raziskav in biomehanike teka. Drugi je komercialni. Torej, kaj je komercialno zanimivega za uporabnika in za trg, kjer gre predvsem za določanje primerne obutve za tekača. Tretji vidik pa je definicija problema s strani računalniškega vida (angl. computer vision).

2.1 Športni vidik

Z razmahom množičnega rekreativnega teka se je povečalo tudi zanimanje strokovne športne javnosti za raziskave na tem področju. Večina raziskav je usmerjenih predvsem v analizo, kako različni dejavniki vplivajo na poškodbe rekreativnih tekačev. Številne so namreč študije vpliva različnih športnih copat na pogostost poškodb pri tekačih in tudi na hitrost in učinkovitost teka [1].

S športnega stališča nas pri teku običajno zanimajo predvsem podatki,


kot so gibanje gležnja v času faze opore in s tem povezan kot v gležnju. To je tako imenovana pronacija. Vendar pri tem ni tako zanimivo, kolikšna je ta pronacija, saj do sedaj še nobena študija ni potrdila, da bi prekomerna pronacija imela kakršenkoli neposreden vpliv na poškodbe tekača [7]. Bolj zanimivo je, za koliko se spremeni sam kot od začetnega stika stopala s podlago do takrat, ko pride do faze odriva stopala od podlage. Prav tako je zanimivo tudi, v kolikšnem času se zgodi ta sprememba, saj predvidevajo, da naj bi ravno hitra in velika sprememba kota v gležnju povzročala predvsem poškodbe ahilove tetive [4]. Vse to je mogoče ugotavljati s posnetkov tekača s hrbtne strani, vendar so to v športu do sedaj po večini določali ročno, saj orodij za avtomatsko določanje teh kotov ni. V najboljšem primeru se za lažje ročno označevanje uporabljajo markerji na tekačih, vendar za avtomatsko prepoznavo markerjev pri nas po večini ne uporabljajo programskih orodij in se zato določajo ročno.

Poleg pogleda od zadaj sta s športnega stališča pri analizi teka zanimiva tudi stranski pogled z leve ali desne strani in pogled s sprednje strani. Pri stranskem pogledu so za analize in raziskave pomembni predvsem koti v vseh treh sklepih spodnjih okončin tekača, torej fleksija in ekstenzija v kolku, kolenu in skočnem sklepu in s tem povezani koti v teh sklepih. Pri tem pogledu je tudi najlažje ugotoviti trenutek in točko stika stopala s podlago, torej, ali se je tekač dotaknil podlage s celim stopalom, s prsti ali peto [4].

Tretji pogled, ki je tudi zanimiv s stališča športa, je pogled s sprednje strani. Tukaj, če se osredotočimo samo na spodnje okončine, je pomembna pot kolena med tekom, predvsem, po kakšni poti potuje koleno v fazi opore preko gležnja in s tem stopala (slika 2.1). Zanima nas, ali prihaja na poti do morebitnih odmikov levo ali desno, torej ali koleno sili navzven ali navznoter [4].

Za analizo in raziskave je treba pridobiti povprečne podatke. Povprečje se računa iz večjega števila korakov, zato je ročno pridobivanje podatkov predvsem časovno zahtevno, obenem pa tudi podvrženo človeški napaki.

Ti podatki so osnova za morebitne nadaljnje raziskave in analize pri



Slika 2.1: Pogled na tekača s sprednje strani, kjer vidimo pot kolena preko stopala.

tekačih. Tako na podlagi pridobljenih podatkov o gibanju gležnja ugotavljajo vplive različnih športnih copat na tek in s tem povezane poškodbe [8–10]. Prav tako se ugotavlja vpliv utrujenosti tekača na tehniko teka in s tem povezane spremembe v kinematiki tekača [11, 12].

Zaradi časovne zahtevnosti pridobivanja potrebnih podatkov za raziskave v športu je motivacija za razvoj podobnih algoritmov, predvsem pa programskih orodij in aplikacij za avtomatsko ali vsaj polavtomatsko analizo teka, zelo velika. Ta bi omogočil dodatno pospešitev in olajšanje številnih raziskav

na področju gibanja tekačev in različnih vplivov na poškodbe, pridobljeno znanje in algoritme pa bi bilo mogoče prenesti tudi na druga področja analiz in raziskav v športu.

2.2 Komerčni vidik

Trgovine s tekaško opremo

Tek je pridobil takšno popularnost, da se z njim vsaj občasno ukvarja že skoraj vsak. Ravno zaradi množičnosti se je iz tega razvil velik ekonomski trg. Ta velik ekonomski potencial se začne že pri nakupu osnovne opreme, ki jo potrebujemo za tek, torej športnih copat. Proizvajalci so seveda razvili športne copate za vse mogoče tipe tekačev, za težje, lažje, hitrejše, počasnejše. V vsej tej poplavi različnih modelov športne obutve se kupec težko odloči za tiste, ki so primerni zanj. Potem so tu še pojmi, kot sta pronacija in supinacija, ki marsikateremu tekaču niso ravno najbolj jasni. V skoraj vseh knjigah, ki so namenjene predvsem tekačem začetnikom, je eden prvih korakov pri začetku ukvarjanja s tekom izbira primerne obutve. To pomeni, da moramo vedeti, kakšen tip tekača smo, saj je to ena prvih stvari, ki jo bo vprašal prodajalec športne obutve.

Danes že skoraj vsaka specializirana trgovina s tekaško opremo izvaja neko obliko merjenja pronacije pri teku. Nekatere izvajajo to z merjenjem odtisa stopala. Pri tem se ugotovi, kako visok stopalni lok ima posameznik, na podlagi tega pa se sklepa o stopnji pronacije. Torej, če ima posameznik nizek stopalni lok, sklepamo, da mu bo noga med tekom silila v pretirano pronacijo, in ga tako označimo za pronatorja. Obratno, če ima nekdo visok stopalni lok, sklepamo, da bo pronacije premalo, in ga označimo za supinatorja.

Naprednejše trgovine in predvsem tiste, ki imajo na voljo več prostora, lahko kupcem omogočijo, da na tekoči preprogi (angl. threadmill) preizkusijo različne športne copate med tekom. Prodajalec lahko med tekom potencialnega kupca tudi opazuje in določi, ali je ta morebiti pronator, nevtralni tekač

ali supinator. To se v večini trgovin določa brez posebnih pripomočkov, le na podlagi izkušenj in znanja prodajalca. Tekača preprosto opazuje med tekom in oceni, kakšen je kot v gležnju v fazi opore. V nekaterih trgovinah imajo na koncu tekoče preproge nameščeno tudi kamero, ki posname tekača. Vendar tudi v tem primeru prodajalci običajno le na podlagi ogleda počasnega posnetka in izkušenj ocenijo, kolikšen je kot v gležnju. V večini primerov ne uporabljajo niti programskih orodij za merjenje kota na posnetku oz. sliki.

Zato bi bilo tudi komercialno zanimivo takim trgovinam ponuditi aplikacijo ali celo kar napravo za avtomatsko določanje tipa tekača. Torej aplikacijo, ki bi s posnetka tekača med tekom na tekoči preprogi, posnetega z relativno poceni kamero, lahko določila tekaču primeren tip športnih copat. Aplikacija bi imela na vходу posnetek tekača, posnetega od zadaj, na izhodu pa rezultat, ali je tekač pronator, supinator ali nevtralni tekač. Tako v trgovinah ne bi bilo več treba imeti izurjenih in izkušenih prodajalcev, da bi ti določali to na podlagi osebne ocene in lastnih izkušenj. Prav tako bi se povečali natančnost in ustreznost samega postopka. Rezultate bi lahko kupec tudi sam vizualno preveril in s tem ugotovil, ali so ustrezni.

Tekaška društva in skupine

V zadnjem času narašča tudi število tekaških društev in organiziranih tekaških skupin. Večina društev in skupin poleg vodenih treningov in nasvetov ponuja različne oblike analize teka in tekaške tehnike. Te analize po navadi zajemajo posnetek tekača, običajno iz treh zornih kotov. Posnetke nato analizirajo strokovni tekaški trenerji. Pri posnetku od zadaj se med analizo ugotavlja predvsem, ali je tekač morebiti pronator ali supinator. Pri posnetku z leve ali desne pa, kakšen je potek noge med tekom, če se pete dvigajo dovolj visoko, kakšni so koti v gležnju, ali je telo nagnjeno preveč naprej, ali gredo kolena dovolj visoko, torej predvsem kote v vseh treh sklepih, kolku, kolenu in gležnju. Ugotavlja se tudi, kako tekač postavlja nogo na podlago, torej s katerim delom stopala se najprej dotakne podlage in ali nogo ob prvem stiku

postavlja pod svoje težišče. Poleg tega se opazuje tudi potek rok in kot v komolcu. Na posnetku s sprednje strani se običajno ugotavlja potek kolena preko gležnja in potek gibanja rok, ki s prsti ne smejo priti preko sredinske linije tekača. Poleg tega se ugotavlja tudi, kako tekač postavlja stopala v smeri gibanja, ali prihaja do morebitnih odklonov v levo ali desno.

Tudi te analize se običajno izvajajo ročno, trener oz. strokovna oseba pregleda posnetke posameznika v katerem od programov, ki omogoča počasno predvajanje in po možnosti vsebuje določena orodja za merjenje kotov, ter z njihovo pomočjo analizira gibanje tekača. Na podlagi analize nato določi morebitne napake in izboljšave v tehniki posameznika. Tudi ta proces bi precej poenostavili in pospešili z morebitnimi aplikacijami, ki bi avtomatsko določale in pridobile določene zahtevane podatke, predvsem kote v posameznih sklepih. Algoritmi in programske rešitve s področja avtomatske analize teka bi bile komercialno zanimive tudi za društva in tekaške skupine, pa tudi za tekače posameznike, ki imajo malo več znanja.

2.3 Vidik računalniškega vida

Računalniški vid je eno izmed področij računalniške znanosti, ki se v zadnjem času precej razvija in je doseglo tudi velik napredek. Del raziskav je povezan z zaznavanjem in sledenjem gibanja na videoposnetkih. Za nas so predvsem zanimive raziskave na področju analize gibanja (angl. gait analysis). Te raziskave so motivirane s stališča prepoznavanja oseb po načinu hoje [13]. Pri našem problemu naletimo na delno podobne zahteve. Namesto hoje analiziramo korak pri teku. Sami postopki so lahko zato po eni strani precej podobni, po drugi pa se pojavijo specifični problemi, ki so povezani s tekom. Če se omejimo samo na povezavo računalniškega vida in področja športa, so možnosti za sodelovanje ogromne. Dobri in robustni sistemi za sledenje in prepoznavanje gibanja bi bili tako v pomoč pri raziskavah na vseh področjih športa. Možnosti za nadaljnji razvoj so tudi na področju virtualnih trenerjev in virtualnih pomočnikov pri vadbi.

Razvoj sledenja in prepoznavanja gibanja je precej napredoval, tudi s pomočjo razvoja sistemov za računalniške igre (recimo Microsoftov sistem Kinect). Obstaja velika motivacija za razvoj takih sistemov, ki bi bili neodvisni in robustni, njihovo delovanje ne bi bilo odvisno od tipa kamere in tega, kje je bil posnet posnetek.

Pri analizi teka se tako iz zornega kota računalniškega vida srečujemo s podobnim problemom kot pri analizi hoje, še posebno pri analizi posnetka tekača od strani. Vendar pa tukaj naletimo na dodatne omejitve predvsem zaradi specifičnosti gibanja pri teku. Tekoč namreč zaradi poskakovanja deloma spreminja višino. Gibanje samo je hitrejše, zato morajo tudi kamere zajemati posnetke z dovolj veliko frekvenco, da ne izgubimo informacij. Prav tako se gibanje samo spreminja glede na to, s kakšno hitrostjo teče tekač. Težave povzroča tudi samoprekrivanje okončin, kar je lahko izrazito na posnetkih iz vseh zornih kotov.

Z vidika računalniškega vida potrebujemo učinkovite algoritme za zaznavo samega tekača, da ga ločimo od statičnega ozadja. Poleg tega moramo čim natančneje zaznati meje tekačevega telesa. Določiti moramo sklepe in skelet. Šele na podlagi tega lahko dobimo ustrezne podatke, ki jih potrebujemo. Sami algoritmi morajo biti čim bolj robustni in seveda čim bolj učinkoviti. Ne smejo biti pretirano občutljivi na različne dejavnike okolja, kot so osvetlitev, tip ozadja, oblačila, obutev tekača in podobno. Prav tako je zaželeno, da so algoritmi hitri in sposobni procesiranja v realnem času.

Možnosti za nadaljnje sodelovanje področja športa in področja računalniškega vida so praktično neomejene. V športu se pri raziskavah in analizah vedno bolj uporabljajo metode in postopki, ki vključujejo tudi 3D-rekonstrukcijo gibanja športnika iz posnetkov, in postopki, ki vključujejo prepoznavanje gibanja in sledenje gibanju športnika s posnetka. Videoanaliza športnih nastopov je pri vrhunskih športnikih že sedaj stalna praksa. Večino teh metod se izvaja ročno, zato so postopki dolgi in zamudni, dragi in podvrženi napakam.

2.4 Motivacija in cilji

V prejšnjih poglavjih smo ugotovili, da je motivacije za razvoj podobnih programskih rešitev za avtomatsko videoanalizo gibanja tekačev, kar je tudi cilj tega diplomskega dela, dovolj. Obstajajo tako ekonomsko komercialne kot tudi strokovne potrebe po podobnih algoritmičnih in rešitvah. Možnosti za razvoj novih algoritmov in rešitev na tem področju so velike. Možnosti uporabe podobnih sistemov so tako na strokovnih področjih kot tudi na področju prodaje športnih izdelkov in ne nazadnje tudi za posameznega uporabnika, torej za osebno uporabo športnikov in rekreativcev.

Cilje tega diplomskega dela smo postavili v sodelovanju s Fakulteto za šport Univerze v Ljubljani:

- Izdelati prototip algoritmov za avtomatsko ali vsaj delno avtomatsko analizo teka.
- Pridobiti in posneti več različnih tekačev med tekom.
- Razviti programsko kodo, ki učinkovito in z zadovoljivo natančnostjo določa kot v gležnju pri tekačih v fazi opore, pri čemer se mora kot v gležnju zaznati s posnetka samega, brez dodatnih pomagal, kot je dodatna posebna osvetlitev, morebitni svetleči markerji na tekaču in podobno.
- Preveriti kako učinkovita in natančna je takšna avtomatska analiza in ali so rezultati pri zaznavi različnih stopenj pronacije zadovoljivi, ali metoda loči med posameznimi tekači ter kako se obnese v primerjavi z ročno metodo.

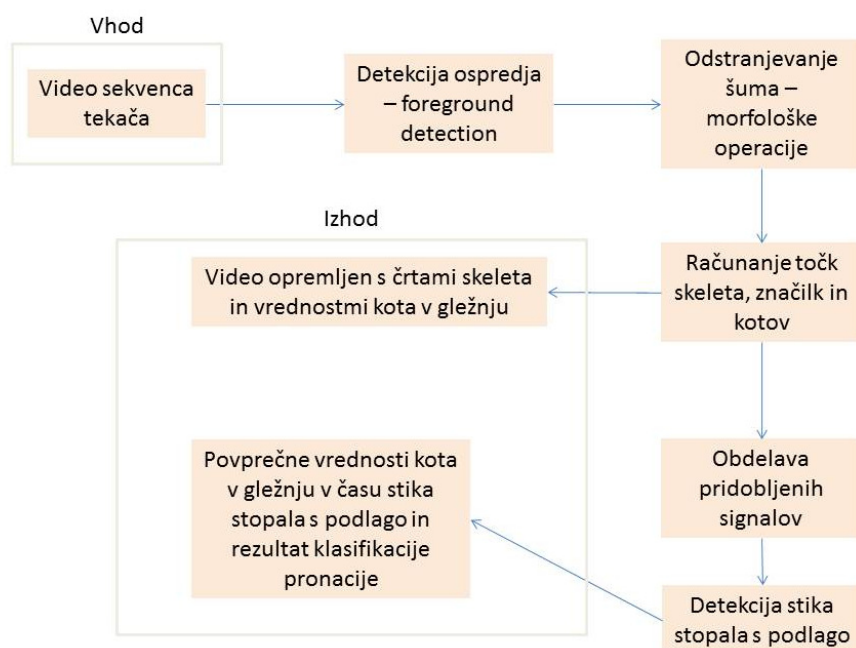
Poglavje 3

Predlagana rešitev

Matlab je programsko orodje, ki omogoča hiter razvoj prototipnih rešitev, zato smo se odločili, da ga uporabimo tudi za razvoj naše rešitve. Prvotno je namenjen uporabi v tehniki in znanosti, a se je izkazal kot zelo primeren za vsakovrstno numerično računanje. S svojimi razširitvami in knjižnicami predstavlja primerno okolje za procesiranje signalov, obdelavo videa in slik in ima posebej podprto področje računalniškega vida. Pri svojem delu smo uporabljali predvsem knjižnico računalniškega vida (angl. computer vision system toolbox – CVST) in knjižnico za procesiranje slik (angl. image processing toolbox). Ti dve knjižnici ponujata podoben nabor funkcij in metod kot knjižnica OpenCV, ki se uporablja v kombinaciji z jezikoma C in C++ ter vsebuje večino metod in funkcij s področja računalniškega vida [14]. Matlab je zelo primeren jezik, ki omogoča hiter razvoj in testiranje različnih rešitev, in to kljub temu, da bi bile te mogoče hitrejše in učinkovitejše, če bi bile napisane v kakšnem drugem programskem jeziku, kot je recimo C ali C++. Pri svojem delu smo uporabljali Matlab R2012A.

3.1 Uporabljeni algoritmi

Prvi korak pri razvoju programske rešitve je, da z videoposnetka izluščimo silhueto tekača. Pri tem smo uporabili funkcijo, ki je del Matlabove knjižnice



Slika 3.1: Diagram poteka rešitve.

računalniškega vida – CVST. To je funkcija `vision.foregroundDetector`. Posnetki so posneti tako, da imajo najprej 10 sekund prazne tekoče preproge in ozadja brez tekača, z namenom, da se algoritem lahko nauči ozadja, šele nato sledi dejanski posnetek tekača med tekom. Rezultate te obdelave nato obdelamo z določenimi morfološkimi operacijami, da v čim večji meri odstranimo šum. Iz te silhuete nato z algoritmom izračunamo skelet tekača, tako da dobimo daljice, ki predstavljajo kosti. S tem tudi približno določimo sklepe. Točko gležnja, ki nas še posebej zanima, določimo bolj natančno. Po pridobljenem skeletu v vsaki sličici posnetka izračunamo kot v gležnju na vsaki nogi. Tako pridobljene podatke nato še obdelamo z operacijami za obdelavo signalov in izračunamo srednje vrednosti, na podlagi katerih nato ocenimo, ali gre za pronacijo ali supinacijo (slika 3.1). Posamezne pomembnejše operacije in algoritme bomo podrobneje predstavili v nadaljevanju.

3.2 Detekcija ospredja

Funkcija za detekcijo ospredja (angl. foreground detection) računa ospredje (angl. foreground) na podlagi adaptivnih mešanih modelov ozadja (angl. adaptive background mixture models). Funkcija se uporablja za detekcijo premikajočih se objektov v sekvenci slik [15].

Sam algoritem primerja vsako točko neke sekvence slik z modelom ozadja ter s tem določi, ali je točka del ozadja ali del ospredja. Kot rezultat vrne masko ospredja. Model ozadja sestavi na podlagi določenega števila učnih slik. Sestavi ga s pomočjo mešanih Gaussovih modelov (angl. Gaussian mixture models – GMM). Metoda modelira vsako točko ozadja z mešanico K Gaussovih porazdelitev. K je običajno majhno število, manjše od pet. Te Gaussove porazdelitve predstavljajo različne možne barve točk. Posamezni modeli, ki predstavljajo točko, so uteženi glede na časovno verjetnost, da se ta barva stalno pojavlja v prejšnjih sličinah. Najverjetnejše barve so torej tiste, ki ostanejo v sceni preko največjega števila zaporednih sličic. Algoritem gibajoče se objekte loči od ozadja na podlagi tega, da različno odsevajo svetlobo in zato pogosteje spreminjajo barvo. Tako pri detekciji vsako točko na sliki primerja z modelom ozadja in preverja razliko, obenem pa tudi sproti uteženo osvežuje model ozadja [15–18].

Spremenljivi mešani Gaussov model – GMM

Vsaka točka v sličici je modelirana z mešanico K Gaussovih porazdelitev. Verjetnost, da ima točka vrednost x_n v času n je:

$$p(x_n) = \sum_{k=1}^n w_k \eta(x_n; \theta_k), \quad (3.1)$$

kjer w_k predstavlja verjetnost k -te komponente Gaussove porazdelitve, η je normalna porazdelitev k -te komponente in jo predstavlja enačba:

$$\eta(x; \theta_k) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma_k|^{\frac{1}{2}}} e^{-\frac{1}{2}(x-\mu_k)^T \Sigma_k^{-1} (x-\mu_k)}, \quad (3.2)$$

kjer θ predstavlja vektor neznanih parametrov, μ_k je povprečje, Σ_k pa kovarianca k -te komponente in D dimenzija spremenljivke x . Pri osveževanju modela je posodobljena prva komponenta porazdelitve, ki se ujema [16–18].

Parametri funkcije

Funkcija `vision.foregroudDetector` v Matlabu ima kar nekaj dodatnih nastavitev. Te lastnosti lahko določamo in spreminjamo. Prva lastnost predstavlja adaptivno učenje (angl. adapt learning rate). Določa sposobnost adaptivnega učenja v času, ki je določen z lastnostjo števila učnih sličic (lastnost `NumTrainingFrames`). Ta lastnost je lahko nastavljena na `true` ali `false` (privzeto je `true`). Število učnih sličic (`NumTrainingFrames`) lahko nastavimo na poljubno število sličic iz katerih se bo algoritem učil modela ozadja. Če je adaptivno učenje nastavljeno na `false`, potem ta lastnost ni na voljo, privzeto število učnih sličic pa je 150. Naslednja lastnost je stopnja učenja (`LearningRate`), ki določa, kako hitro se model prilagaja spremenjenim pogojem po koncu učnih sličic. Tudi ta lastnost ni na voljo, če je adaptivno učenje nastavljeno na `false`, privzeta vrednost pa je 0,005. Minimalno razmerje ozadja (`MinimumBackgroundRatio`) je prag, ki določa model ozadja in predstavlja minimalno apriorno verjetnost, da so točke del ozadja. Privzeta vrednost je 0,7. Število Gaussovih porazdelitev (`NumGaussians`) predstavlja K , torej število Gaussovih modelov za posamezno točko v GMM. Po navadi so vrednosti med tri in pet, privzeta vrednost je pet. Začetna varianca (`InitialVariance`) je začetna varianca pri inicializaciji novega Gaussovega modela in inicializira vse porazdelitve modela. Po navadi je ta vrednost okoli 30^2 za integer ali približno $(\frac{30}{255})^2$ za operacije v plavajoči vejici, kar je tudi privzeta vrednost [15].

S poizkušanjem, katere lastnosti nam dajo najlepšo silhueto tekača, smo v našem primeru določili vrednosti posameznih lastnosti, ki smo jih uporabili pri obdelavi. Stopnjo učenja smo nastavili na 0,00000001, saj ne želimo, da bolj statične dele tekača zaznamo kot del ozadja, število učnih sličic smo

nastavili na petnajst, saj je večje število vneslo v silhueto dodaten šum, začetna varianca pa je bila 30^2 . Ostale lastnosti so nastavljene na privzete vrednosti. Detekcijo ospredja izvajamo na posnetku v barvnem prostoru RGB. Primer maske, ki jo dobimo na izhodu detekcije ospredja, je viden na sliki 3.2.



Slika 3.2: Rezultat detekcije ospredja.

3.3 Morfološke operacije

Kot rezultat funkcije za detekcijo ospredja dobimo masko ospredja. To je binarna slika ospredja, vendar je ta slika precej groba (slika 3.2). Vsebuje precej šuma. Silhueta tekača ima lahko kar nekaj lukenj in ni zvezna. Zato je treba to masko pred nadaljnjim računanjem obdelati. To naredimo z določenimi morfološkimi operacijami nad slikami, ki so tudi že vgrajene v Matlab [19].

Najprej videosekvenco mask, ki smo jo pridobili s funkcijo zaznavanja ospredja, pretvorimo v črno-belo sliko in nato video pretvorimo v barvni prostor intenzitete (angl. intensity). Nato vsako sliko sekvence posebej obdelamo s funkcijo `morph`.

Znotraj funkcije najprej izvedemo operacijo morfološkega zapiranja (angl. close), nato operacijo morfološkega odpiranja (angl. open), zatem izvedemo dilacijo in nato odstranimo še vsa območja, manjša od določene velikosti, da se znebimo šuma.

Morfološke operacije zapiranja in odpiranja

Prva operacija, ki jo uporabljamo, je morfološko zapiranje (angl. morphological close). To je operacija, ki je sestavljena iz dilacije, ki ji sledi erozija in zmanjša luknje v ospredju. Uporabimo jo zato, da delno zapolnimo manjše luknje v silhueti tekača. Tej operaciji sledi operacija morfološkega odpiranja (angl. morphological open). To je operacija, ki je sestavljena iz erozije, njej pa sledi dilacija. Ta operacija posledično odstrani manjši šum in napake v ospredju. Obe operaciji uporabljamo s pomočjo Matlabove funkcije `bwmorph` [16, 19].

Dilacija

Nad dobljeno sliko nato izvedemo dilacijo, s katero po potrebi zapolnimo morebitne večje luknje v silhueti tekača. Dilacija doda nekaj napake v silhueto tekača, vendar mislimo, da bistveno ne vpliva na natančnost rezultata, saj je napaka večinoma enakomerna na vseh straneh silhuete.

Binarna dilacija A in B je označena kot $A \oplus B$. Definirana je kot

$$A \oplus B = \left\{ z \mid (\hat{B})_z \cap A \neq \emptyset \right\}, \quad (3.3)$$

kjer \hat{B}_z predstavlja množico z točk, kjer določen strukturni element, ki ga uporabljamo pri dilaciji, ko ga premaknemo na točko z , prekriva točke v A [20].

Dilacijo izvedemo z operacijo v Matlabu imenovano `imdilate`. Funkcija zahteva na vhodu tudi strukturni element, ki je v našem primeru ustvarjen kar s funkcijo `strel` v Matlabu. To je funkcija, ki ustvari morfološki strukturni element (angl. morphological structuring element). V našem primeru v končni rešitvi uporabimo kar kvadrat, širine 6. Če pri posnetku ni večjih lukenj, se poizkušamo dilaciji izogniti oziroma za strukturni element uporabimo manjši kvadrat [16, 20].

Odstranitev manjših objektov

Zadnja operacija, ki jo izvedemo v tem sklopu, služi odstranitvi morebitnih večjih napak iz maske, torej manjših objektov, ki so zaznani poleg tekača. To storimo z operacijo `bwareaopen` v Matlabu. Ta operacija odstrani iz slike povezana območja točk, ki so manjša od določene velikosti. Operacijo izvedemo s privzetim parametrom povezanosti, ki je nastavljen na 8 povezanih sosedov, velikost povezanega območja pa mora v končni rešitvi biti večja od 7500 točk [21].

S temi operacijami dobimo očiščeno masko, ki po večini vsebuje lepo, sklenjeno in polno silhueto tekača. Še vedno pa so v silueti napake, vendar je večina teh napak posledica senc in samoprekrivanja tekačevih nog. Tako se spodnji del nog rahlo zlije s stezo in tudi nogi se večkrat zaradi samoprekrivanja spodaj zlijeta v eno silhueto. Primer dobljenega rezultata je viden na sliki 3.3.

Po končanih morfoloških operacijah pridobimo še podatke o masi silhuete, centru silhuete, maksimalni višini silhuete ter maksimalni širini silhuete v okolici kolen. Masa silhuete je število vseh točk, ki sestavljajo silhueto. Te podatke zajamemo z namenom boljše detekcije ciklov v kasnejši obdelavi signalov. Center silhuete, maksimalna višina in maksimalna širina silhuete v okolici kolen so vidni tudi na sliki 3.6, kjer so izrisani z zeleno barvo.



Slika 3.3: Silhueta tekača po izvedbi morfoloških operacij.

3.4 Določanje skeleta

Potem ko pridobimo očiščen posnetek silhuete tekača med tekom, lahko začnemo s procesiranjem te silhuete. Tako se lotimo postopka pridobivanja skeleta tekača. Skelet tekača sestavljajo približne premice, ki potekajo po sredini spodnjih okončin tekača. V prvi fazi iz silhuete pridobimo posamezne segmente, iz katerih nato izračunamo sredino. Temu sledi računanje sredine okončin, nato določimo še točko gležnja in izračunamo kot v tej točki.

Računanje segmentov

Najprej pridobljeno sliko silhuete tekača razrežemo na štiri dele. Ročno postavimo mejo, kjer so tla, saj pod to mejo preostanek slike zavržemo in ga ne obdelamo. Zgornji del te slike razdelimo v grobem na tri dele, spodnji del nog z gležnjem, zgornji del nog ter ostanek, ki predstavlja telo tekača. To

naredimo kar ročno s približnimi mejami, lahko bi tudi izračunali približne meje glede na višino tekača, saj so razmerja dolžin posameznih delov okončin glede na višino pri človeku znana. Ključno je edino to, da natančno določimo mejo podlage, torej spodnjo višino, pod katero tekač ne more biti. Na sliki 3.4 so posamezni segmenti obrobjeni z rdečo črto, meje med segmenti pa označujejo rdeče vodoravne črte.

Pridobljene dele slike nato obdelamo tako, da iz silhuete dobimo posamezne segmente. Ti so predstavljeni kot množica točk, ki predstavljajo sklenjen rob segmenta. Segmente pridobimo s funkcijo `bwboundaries` [22], ki je vgrajena v Matlabu. Ta za vhod vzame dele slik in vrne zunanje meje območij, ki jih najde na tem delu slike. Prav tako funkcija v osnovi vrne tudi meje lukenj v silhueti, zato jo poženemo z dodatnim argumentom `noholes`, ki išče samo objekte brez lukenj, torej našo silhueto, in vrne zunanje meje le-teh. Sama funkcija nam vrne matriko mej objektov in matriko, ki vsebuje oznake posameznih objektov, tako da vemo, s katerega dela slike so. Funkcija ima tudi argument `conn`, ki predstavlja povezljivost. Pri tem uporabimo privzeto vrednost 8 povezanih okolic. Segmenti so vidni na sliki 3.4.

Potem ko pridobimo meje objektov na posameznih delih slik, je potrebnega še nekaj dodatnega procesiranja. Najprej za vsak del slike razporedimo pridobljene segmente po velikosti. Nato v naš rezultat najdenih segmentov dodamo največjega. Preverimo še, ali je ostalo v tem delu slike še kaj najdenih segmentov. Če zaznani segment ni edini, dodamo na izhod še drugi največji segment, če je dovolj velik. V našem primeru smo drugi segment dodajali le, če je bil po velikosti večji kot 40 % največjega segmenta, kar smo določili eksperimentalno. To se je zgodilo v primeru, če smo v delu slike imeli obe nogi ločeni. Torej je zaznal vsako kot ločen segment in smo zato v rezultat vključili oba.

Rezultat tega dela procesiranja so meje segmentov tekača s posameznih delov slike, s pripadajočimi oznakami, da vemo, v kateri del slike spadajo. V vsakem delu slike imamo tako najmanj en segment in največ dva.

V končni rešitvi posnetke segmentiramo različno glede na posamezno sne-

manje, saj se zajeti kader na različnih snemanjih rahlo razlikuje. Posnetke iz prvega dne snemanja segmentiramo v tri segmente in jim pripišemo pripadajoče oznake, in sicer od višine 1 do 80 pik je prvi segment z oznako 1, od višine 80 do 280 pik drugi segment z oznako 2 in od višine 280 do 355 pik je tretji segment z oznako 3. Zadnja višina predstavlja tudi približen nivo podlage na posnetku. Posnetke iz drugega dneva snemanja pa delimo v segmente od višine 1 do 80 pik v prvi segment z oznako 1, od višine 80 do 280 pik v drugi segment z oznako 2 in od višine 280 do 375 pik v tretji segment z oznako 3.

Računanje sredine okončin, točk za določitev skeleta in premic

Naslednja faza je obdelava posameznih segmentov z namenom, da pridobimo točke skeleta. Segmente obdelamo ločeno glede na oznake, ki jih imajo. Najprej obdelamo segmente z oznako 1. Ti predstavljajo zgornji del slike, torej boke tekača. Ker za naše računanje ti niso pretirano pomembni, segment obdelamo zelo enostavno, izračunamo le dolžino segmenta in sredinsko točko, tako da potegnemo le daljico po sredini segmenta. Na sliki 3.4 jo označuje navpična črna črta v zgornjem segmentu.

Temu sledi obdelava segmentov z oznako 2. Ti predstavljajo zgornje dele nog. Po navadi dobimo tu le en segment, saj se noge v zgornjem delu običajno zlijejo skupaj v en segment, lahko tudi zaradi hlač, ki jih ima tekač oblečene. Najprej izračunamo množico točk, ki predstavlja sredinske točke segmenta. To storimo tako, da gremo po višini segmenta in za vsako višino izračunamo točko, ki predstavlja sredino segmenta. V primeru, ko imamo samo en segment in sta na zgornji strani segmenta nogi zlití skupaj, začnemo računati sredino od spodaj navzgor, saj bi morali spodaj nogi zaznati še ločeno. V vsaki višini preverimo, ali so za to višino na voljo natanko štiri točke, torej točke, ki predstavljajo zunanji in notranji rob vsake noge. Večje število zaznanih točk pomeni, da imamo napako v silhueti tekača, in teh točk ne upoštevamo. Če je teh točk manj, sta nogi zlití skupaj, zato ne moremo

natančno določiti sredinske točke posamezne noge na tej višini. Upoštevamo torej samo tiste višine, kjer najdemo natanko štiri točke. Iz teh štirih točk izračunamo sredino leve in desne noge ter ju shranimo na izhod. Pri tem smo vpeljali še dodatno varovalo, ki preprečuje, da bi dodajali tudi točke sredine, ki so precej odmaknjene od povprečne sredine. Za take točke namreč lahko z gotovostjo trdimo, da so napačne, razen če ima tekač na nogah kakšne velike izrastke. Primer take napake v silhueti, kjer ne upoštevamo sredinskih točk, ker so preveč odmaknjene od povprečja, je na sliki 3.4 označen s puščico. Sproti računamo povprečje sredinskih točk za vsako nogo, novo točko pa dodamo na izhod le, če se malo razlikuje od povprečja, torej če je znotraj okolice desetih pik od povprečja, kar smo določili eksperimentalno. V nasprotnem primeru take sredinske točke izključimo, saj obstaja velika verjetnost, da predstavljajo napako v silhueti. Ker je človeška noga v zgornjem delu relativno ravna, točke, če ne gre za napako, ne smejo veliko odstopati od povprečja. Ker pa smo začeli procesiranje na spodnji strani, kjer bi morali biti nogi zaznani ločeno, računamo sredino posamezne noge vse do višine, kjer je ta zaznana ločeno od druge.

S tem pridobimo množico sredinskih točk za posamezen del vsake noge. Iz množice teh točk nato za vsako nogo z algoritmom `hough_fit_line` določimo črte, ki potekajo skozi te točke, ter začetno in končno točko te daljice shranimo kot ključne točke skeleta. Sredinske točke so na sliki 3.4 označene s črnimi pikami.

Algoritem `hough_fit_line` množici sredinskih točk aproksimira daljico, ki poteka skozi njih. To stori tako, da poizkuša najti primerno Houghovo transformacijo, ki ustreza poteku točk.

Vsako premico določa par smernega koeficienta in začetne vrednosti. Premica je v ravnini natančno določena z dvema paroma točk. Po Houghovi transformaciji spremenimo eksplicitno enačbo premice s smernim koeficientom in začetno vrednostjo v par θ in ρ , kar je enačba v polarnih koordinatah [14]. To je predstavitev, ki ravno tako določi premico enolično. V taki obliki predstavitve ρ označuje oddaljenost najbližje točke na premici od



Slika 3.4: Primer izrisanih segmentov tekača, sredinskih točk po segmentih in pridobljenih premic.

izhodišča, θ pa naklonski kot normale na premico. Premico po Houghovi transformaciji lahko zapišemo z enačbo

$$x \cos \theta + y \sin \theta = \rho. \quad (3.4)$$

Pri tem θ omejimo na interval $[0, \pi)$. Torej, če imamo množico točk (x_i, y_i) , skozi katere želimo potegniti premico, vsako točko preobrazimo v Houghov prostor, tako da predstavlja sinusoido, po enačbi

$$\rho = x_i \cos \theta + y_i \sin \theta. \quad (3.5)$$

Tako dobimo za vsako točko vse možne premice, ki potekajo skozi njo. Sam algoritem določanja pravilne premice je glasovalen. Vsaka od točk odda glasove za vse premice, ki bi lahko potekale skozi njo. To se običajno naredi v matriki, nato se le še poišče lokalni maksimum, ki predstavlja premico, ki gre skozi največ točk [14, 23].

V primeru, da imamo nogi ločeni in sta torej vsaka v svojem segmentu, enostavno obdelamo vsak segment posebej. Izračunamo sredinske točke vsakega segmenta. Pri tem upoštevamo samo tiste sredinske točke, ki so znotraj neke okolice povprečja (deset pik). Nato skozi te točke potegnemo premico s pomočjo Houghovega algoritma. Na koncu shranimo začetne in končne točke segmentov kot ključne točke skeleta. Torej sama obdelava poteka podobno, kot če imamo le en segment, le da se tu vsaka noga procesira ločeno.

Sledi obdelava segmentov, ki imajo oznako 3 in predstavljajo spodnji del nog, vključno s stopali. Tudi tukaj se obdelave lotimo podobno kot pri prejšnjih segmentih. Tu večinoma dobimo le en segment, saj sta nogi na spodnjem delu pri stopalih zlitih skupaj v isti segment, običajno tudi zaradi sence tekača, ali pa je v spodnjem delu slike le ena noga, saj je druga pokrčena in dvignjena višje. Torej v tem primeru ločimo dve možnosti nadaljnjega procesiranja. V primeru, da imamo le en segment, preverimo njegovo širino. Če ta širina presega 60 % skupne največje širine segmentov v višjem delu, se procesiranje lotimo podobno kot v zgornjem primeru. Najprej izračunamo sredinske točke vsake noge. To storimo s podobnim algoritmom kot pri obdelavi zgornjih delov nog. Vendar začnemo tu procesiranje od zgoraj navzdol, saj sta na zgornjem delu pri kolenih nogi običajno še zaznani ločeno. Pri izračunu sredinskih točk prav tako upoštevamo samo tiste točke, na višini katerih zaznamo natanko štiri različne točke, ki predstavljajo meje posamezne noge. Če to ni tako, potem te sredinske točke zavržemo. Tudi tukaj imamo omejitev glede povprečja, torej zopet upoštevamo samo sredinske točke, ki so v okolici šest pik okoli povprečja.

V primeru, da je spodaj zaznan en segment, ki je ožji od 60 % največje širine zgornjih segmentov, potem smo zaznali le eno nogo. Sedaj je treba določiti, ali je to leva ali desna. To izračunamo s pomočjo najbolj leve in najbolj desne točke segmenta. Te točke iščemo samo v začetnem zgornjem delu segmenta, saj je v spodnjem delu segmenta pogosto skupaj z nogo zaznan tudi del podlage. Te točke morajo biti znotraj določenega območja, torej, če so bolj levo, gre za levo nogo, če pa so bolj desno, gre za desno nogo.

Ker tekači stopajo na podlago zelo različno, nekateri stopajo tudi zelo proti sredini, smo postavili meje tako, da mora biti najbolj desna točka bolj desno od $\frac{2}{3}$ širine segmenta v zgornjem delu nog. Minimum, torej najbolj leva točka desne noge, pa mora biti bolj desno od $\frac{1}{3}$. Nato izračunamo sredinske točke segmenta, ki ga zaznamo, in določimo ključne točke za tisto nogo, ki smo jo zaznali.

V primeru, da imamo nogi zaznani v ločenih segmentih, procesiramo vsak segment posebej. Določimo sredinske točke vsakega segmenta. Tudi tukaj upoštevamo omejitev, da so sredinske točke znotraj okolice šest pik okoli povprečja.

Procesiranje poteka naprej enako ne glede na to, ali smo zaznali en segment ali dva. Najprej točke razdelimo v dve skupini, in sicer na točke nad gležnjem in točke pod gležnjem. Veliko težav smo imeli s tem, kako ugotoviti, kje se te točke naravno lomijo, torej kje je točka gležnja (glej poglavje 3.5). Za vsako množico točk nato ločeno določimo premico z Matlabovo funkcijo `polyfit`. Te premice na sliki 3.4 označujejo rumena, zelena, modra in rdeča črta.

Polyfit je algoritem, ki s pomočjo danih točk določi koeficiente polinoma, ki poteka skozi njega. Pri tem določimo stopnjo polinoma. Ta je v našem primeru 1, saj iščemo premice. Sama funkcija torej vrne koeficiente polinoma.

Ko smo določili premice, smo glede na dolžino segmenta in točko gležnja za vsako nogo shranili ključne točke skeleta in izračunali kot v gležnju.

3.5 Določanje točke gležnja

Pri določanju točke gležnja smo imeli veliko težav. Prva možnost je, da bi ugotovili, kje se množica sredinskih točk naravno zlomi. Poizkušali smo z aproksimacijo polinoma višje stopnje skozi te točke, da bi mogoče z določitvijo temena dobili točko gležnja. Vendar so se ti poskusi izkazali za neučinkovite. Druga možnost je morebitna uporaba katerega od algoritmov za gručenje točk, ki bi nam točke razdelil v dve skupini, vendar tukaj skupine niso ja-

sno ločene, zato so bili tudi ti poskusi neuspešni. Na koncu smo se odločili za približno rešitev, ki je po našem mnenju omogočila zadovoljive rezultate. Rešitev izhaja iz anatomskih značilnosti človeka. Pri večini ljudi je noga na spodnjem delu najožja ravno nad gležnjem. To dejstvo smo izkoristili za določitev točke gležnja. Pri računanju sredinskih točk posamezne noge zato dodatno izračunamo še, na kateri višini je noga najožja. Ker pa je ta točka običajno tudi do nekaj centimetrov nad gležnjem, za točko gležnja vzamemo sredinsko točko malo nižje. To določimo kar ročno, tako da jo spustimo za dvajset pik, lahko pa bi jo izračunali tudi kot odstotek višine tekača ali kot razmerje z izmerjeno ožino. Ko določimo točko gležnja, na podlagi te točke razdelimo sredinske točke noge na dve množici, točke, ki so nad točko gležnja, in točke, ki so pod točko gležnja. Iz njih aproksimiramo dve premici, ki sta vidni tudi na sliki 3.4.



Slika 3.5: Označen kot, ki nas zanima.

Kot v gležnju, torej kot v točki 3 na posamezni nogi, nato izračunamo kot

presečišče premic. Kot, ki nas zanima, je torej kot na zunanji strani posamezne noge med premico nad gležnjem in premico pod gležnjem, na sliki 3.5 je označen zeleno, točka 3 pa je v vrhu tega kota. Iz ključnih točk skeleta, ki jih na sliki 3.5 označujejo rdeči krogci, izračunamo smerne koeficiente premice nad gležnjem in premice pod gležnjem. Premico nad gležnjem izračunamo s pomočjo druge in tretje zaznane točke na posamezni nogi. Premico pod gležnjem pa s pomočjo tretje in četrte zaznane točke. To storimo s pomočjo enačbe linearne funkcije, torej

$$k = \frac{y_2 - y_1}{x_2 - x_1}. \quad (3.6)$$

Kot nato izračunamo s pomočjo dobljenih smernih koeficientov, s pomočjo enačbe za izračun kota med dvema premicama


$$\tan \varphi = \left| \frac{k_1 - k_2}{1 + k_1 k_2} \right|. \quad (3.7)$$

Ker pri tem izračunu dobimo ostri kot med premicama, moramo rezultate s pomočjo suplementarnih kotov dodatno preoblikovati, da dobimo želeni kot; na primer med premicama z izračunom dobimo ostri kot, ki znaša v našem primeru le nekaj stopinj, zato moramo ta kot odšteti od 180° , da dobimo želeni kot, ki je topi kot med premicama. Na podoben način izračunamo tudi kote pri ostalih ključnih točkah skeleta, da so nam lahko v pomoč pri obdelavi signalov.

Kot rezultat v končni rešitvi dobimo po tej fazi tudi videoposnetek tekača (slika 3.6), na katerem so vrisane točke skeleta in črte, ki predstavljajo linije po sredini noge. Prav tako je video opremljen s podatki o kotu v gležnju za levo in desno nogo. Obenem shranimo vse podatke v podatkovno strukturo za vsako sličico posebej.

3.6 Obdelava signalov

Pridobljene podatke o kotih in ključnih točkah skeleta je zaradi šuma, napak in neznanih vrednosti treba procesirati in obdelati. Te podatke lahko vzamemo kot surove podatke. Zajemali smo podatke o ključnih točkah skeleta



Slika 3.6: Primer rezultata obdelave: posnetek tekača z označenimi daljicami in točkami na nogah ter izpisanimi koti za vsako nogo.

in kote v vseh teh točkah. Tek je podobno kot hoja po svoji naravi ciklično gibanje, torej se vsak korak ciklično ponavlja. To dejstvo zato izkoristimo za obdelavo surovih signalov, pri čemer prva faza obsega določitev tako imenovanega cikla koraka (angl. gait cycle). Za to moramo določiti neko točko, ki bo služila kot začetek vsakega cikla. Cikel koraka lahko obsega čas od trenutka, ko pride desna noga v stik s podlago, do trenutka, ko ta noga ponovno pride v stik s podlago. Najprimernejši signali za detekcijo cikla so signali, ki opisujejo vertikalno gibanje ali maso silhuete, torej število vseh pik, ki sestavljajo silhueto. Za detekcijo našega cikla si v končni rešitvi izberemo kar maso silhuete, ker da najboljše rezultate pri detektiranju ciklov pri vseh posnetkih. Maso silhuete za posamezno sličico pridobimo, preden silhueto razrežemo na posamezne segmente, torej takoj po končanih morfoloških operacijah. Ta signal analiziramo z diskretnim Fourierjevim transformom

(DFT), da s tem pridobimo frekvenčni spekter, na podlagi katerega potem določimo cikel in frekvenco koraka [24].

Signali so polni napak in nepravilnih vrednosti, ki se pokažejo kot vrhovi v signalu. Te vrhove zaznamo s pomočjo premičnega medianinega filtra preko celega signala. Ta filter nam omogoči zaznavo lokalnih vrhov v signalu. Sprva izračunamo razliko $d(t)$ med signalom $s(t)$ in premično mediano $s_m(t)$, nato pa zaznamo lokalne vrhove v signalu s pomočjo enačb

$$d(t) = \|s(t) - s_m(t)\|, \quad (3.8)$$

$$s(t) = \begin{cases} NaN, & d(t) > \alpha * 1.4826 * s_{m\sigma}(t) \\ s(t), & \text{drugače} \end{cases}, \quad (3.9)$$

kjer je $s(t)$ vrednost signala v času t , α pa parameter, ki določa velikost vrhov. $s_{m\sigma}$ je odklon mediane, ki je podoben standardnemu odklonu, le da je izračunan na osnovi mediane. Skaliranje mediane za faktor 1,4826 nam da absolutno mediano, ki je v povprečju enaka standardnemu odklonu za Gaussove porazdelitve. Ko zaznamo vrh, tam nastavimo vrednosti signala na NaN (angl. not a number); teh vrednosti nato ne upoštevamo. [24].

Tako procesirane signale nato razrežemo na cikle. To naredimo na podlagi določenih začetkov posameznega cikla. Tako bi morale biti začetne in končne vrednosti posameznih ciklov precej podobne. Zaradi šuma v segmentaciji pa to ni vedno tako. Signale zato prilagodimo, da se ujemajo. Signale cikliziramo tako, da poiščemo razliko med začetki in konci ciklov, nato pa interpoliramo signal, da negiramo to razliko s pomočjo enačbe

$$S_i = S_i - \frac{2i - (L - 1)}{2(L - 1)} * D, \quad (3.10)$$

kjer je S del signala, ki ustreza določenemu ciklu, S_i je vrednost v točki i tega cikla, L je dolžina cikla, D pa je razlika med začetkom in koncem cikla. Prav tako posamezne cikle nato ponovno vzorčimo s pomočjo interpolacije in decimacije, da dobimo enotne dolžine. Na obdelanih in očiščenih signalih lahko potem izračunamo tudi vrednosti median po vseh korakih za vsako točko cikla [24]. Primer izhodnih grafov detekcije cikla z izrisanimi povprečnimi

vrednostmi preko cikla prikazuje slika 3.7. Na sliki 3.7 je predstavljenih nekaj opazovanih spremenljivk, `leva3X` in `leva3Y` predstavljata x in y koordinato točke levega gležnja, `leva3theta` pa kot v levem gležnju. Spremenljivke `desna3X`, `desna3Y` in `desna3theta` predstavljajo x in y koordinate gležnja desne noge in kot v gležnju desne noge. Spremenljivka `mass` predstavlja maso silhuete, `objectCenterY` y koordinato sredinske točke silhuete, `MaxY` pa maksimalno višino silhuete. Na vseh grafih predstavljajo modre črte vrednosti za posamezen cikel koraka, rdeča črta pa mediano vseh ciklov koraka.

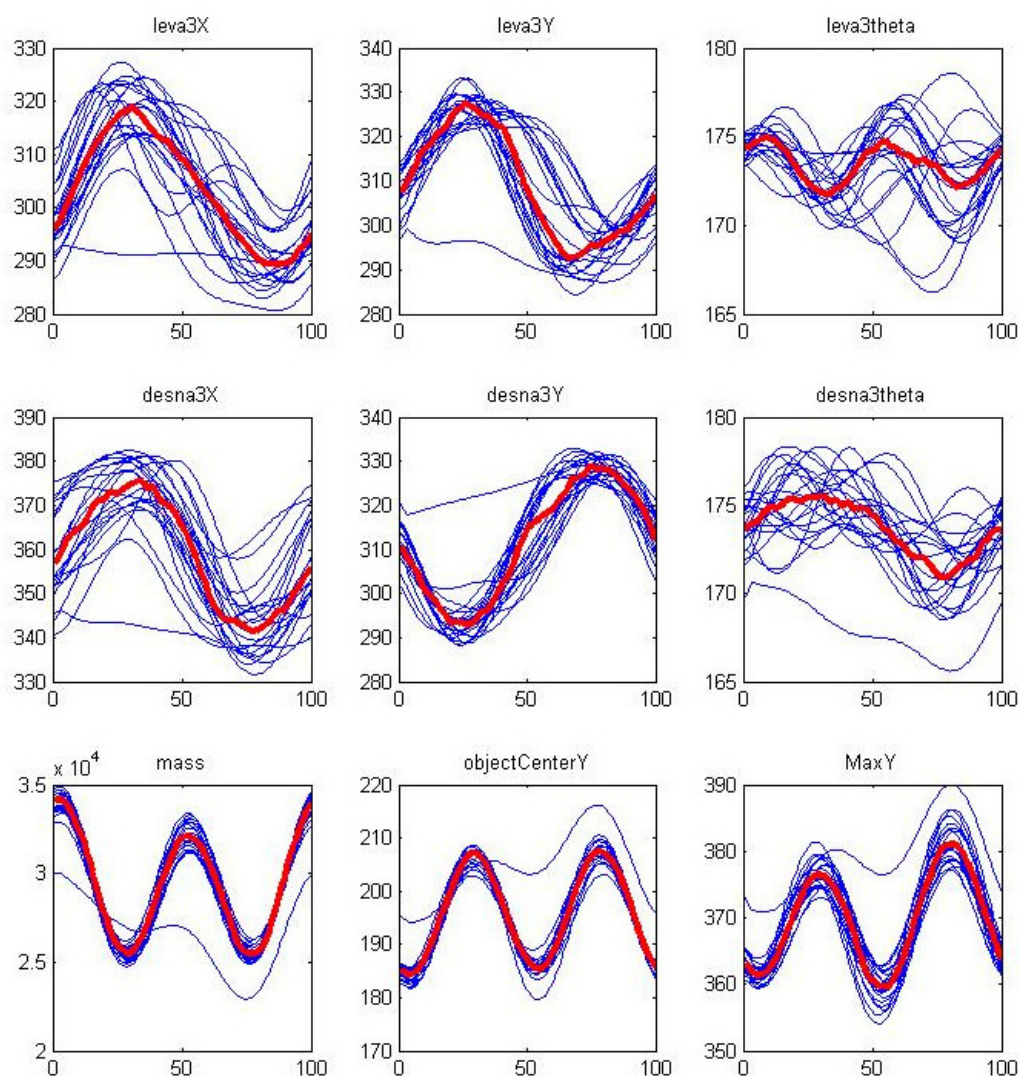
3.7 Določanje faze opore

Fazo opore, oziroma bolje rečeno čas, ko je posamezna noga v stiku s podlago, določamo na tri načine. Ta čas je ključnega pomena, saj nas kot v gležnju zanima le v tem času.

Prva metoda, s pomočjo katere določamo čas stika posamezne noge s podlago, je ročna. Ročno določimo deleže časa, ko je posamezna noga v stiku s podlago v najmanj treh ciklih, nato pa to povprečimo in dobimo deleže časa, ki jih uporabimo za izračun povprečnih vrednostih kota v ciklu.

Druga metoda je avtomatska. Fazo, ko je noga v stiku s podlago, določamo s pomočjo višine zaznane točke gležnja. Točka gležnja mora imeti višino znotraj določenega intervala, kjer je gleženj, ko je noga na tleh. Ta interval določamo ročno, pri posnetkih s prvega snemanja je ta interval [305...315], pri posnetkih z drugega snemanja pa je interval [315...325]. Metoda se je izkazala za dokaj nenatančno, saj je na ta način pridobljeni delež cikla, ko je posamezna noga v stiku s podlago, znašal skoraj polovico cikla za posamezno nogo. Ročni deleži so znašali med 10 % in 17 %.

Tretja metoda je ravno tako avtomatska. Tudi pri tej določamo fazo stika noge s podlago s pomočjo višine zaznane točke gležnja. Tokrat v signalu višine točke gležnja poiščemo največji lokalni maksimum in za čas stika noge s podlago določimo fiksno okolico okoli te točke. Za velikost okolice vzamemo povprečni delež stika noge s podlago, ki ga izračunamo iz ročno pridobljenih



Slika 3.7: Grafi posameznih opazovanih spremenljivk v ciklu tekača.

vrednosti. V primeru, da sta zaradi napak v signalu lokalna maksimuma obeh nog zelo blizu skupaj, za drugo nogo vzamemo drugi največji lokalni maksimum, ki je oddaljen od prvega vsaj za 40 % dolžine cikla. Tudi ta metoda določa stik s tlemi s kar nekaj napakami. Posamezni intervali so običajno malo zamaknjeni od ročno pridobljenih vrednosti, večinoma proti naslednjemu delu stika noge s podlago.

Na podlagi povprečnih sredinskih vrednosti, ki jih pridobimo po obdelavi

signalov, nato določimo maksimalen kot v gležnju, medtem ko je noga v stiku s podlago. Vsaka metoda za detekcijo stika stopala s podlago nam da del povprečnega cikla, ko je posamezna noga v stiku s podlago. Nato vzamemo podatke o povprečnih vrednostih kota za vsako nogo na teh delih cikla. S pomočjo teh vrednosti nato izračunamo povprečen, maksimalen in minimalen kot znotraj delov cikla, ko je posamezna noga v stiku s podlago.

Torej je delni rezultat našega programa vizualna predstavitev, posnetek tekača, opremljen s premicami po sredini noge, označenimi točkami in izpisanim kotom v gležnju za vsako nogo (glej sliko 3.6). Končni rezultat pa je povprečen, minimalen in maksimalen kot za vsako nogo v času, ko je ta na tleh, povprečen za vsaj 20 korakov tekača.

Poglavje 4

Zajem testnih podatkov

Področje, na katerem smo se odločili za izvajanje raziskave in s tem preverjanje, ali bi bila mogoča realizacija avtomatske analize teka, je do danes v Sloveniji še neraziskano. Zato tudi ni primernih posnetkov, ki bi jih lahko uporabili kot temelj za preverjanje in razvoj naših algoritmov. Ker jih nimajo tudi v trgovinah, ki že izvajajo določanje stopnje pronacije in podobne analize pri tekačih med tekom na tekoči preprogi, smo morali posnetke pridobiti sami. V sodelovanju s Fakulteto za šport Univerze v Ljubljani smo opravili na tekoči preprogi v Laboratoriju za fiziologijo tako začetna poizkusna snemanja kot tudi finalno snemanje, prav tako so nam zagotovili tudi ustrezne kamere za snemanje in ostalo potrebno opremo.

Kljub temu, da je področje našega dela še dokaj neraziskano, smo našli nekaj podobnih raziskav v športu in s področja računalništva [8, 9, 11–13, 25], s pomočjo katerih smo pridobili določene informacije, kako zajeti posnetke.

4.1 Poizkusno snemanje

Najprej smo se odločili za poizkusno snemanje. Za to snemanje smo se odločili z namenom, da preizkusimo različne postavitve kadra, osvetlitve in postavitve ozadja. Namen pa je bil tudi, da pridobimo nekaj posnetkov, na podlagi katerih smo nato razvijali algoritem. Na poizkusnem snemanju smo

posneli dva tekača. Po načinu teka in stopnji pronacije sta bila zelo različna. Snemanje smo izvedli s tremi kamerami. Ena kamera je snemala tekača s sprednje strani, druga z desne, s tretjo kamero pa smo snemali tekača od zadaj.

Poizkusno snemanje nas je opozorilo na napake in malenkosti, na katere smo morali paziti pri finalnem snemanju. Eno od težav so nam povzročile kamere, ki so se med snemanjem malenkost premaknile, kar je zmanjšalo kvaliteto delovanja algoritma za detekcijo ospredja. Ugotovili smo tudi, da je osvetlitev laboratorija dovolj močna in zagotavlja dovolj svetlobe za snemanje, tako da dodatna osvetlitev ni bila potrebna. Določili smo najprimernejšo velikost kadra za zajem tekačev. Poizkusno snemanje je tudi pokazalo, da je njihova koža dovolj kontrastna glede na temno ozadje in je detekcija ospredja dovolj kvalitetna, tako da tekači ne potrebujejo posebnih oblačil za snemanje, le oprijete in čim krajše tekaške hlače.

4.2 Finalno snemanje

Na podlagi napak, ki so se pokazale med razvojem algoritma, in v dogovoru z dr. Alešem Dolencem s Fakultete za šport Univerze v Ljubljani smo postavili zahteve, ki smo jih upoštevali pri zajemu posnetkov na finalnem snemanju. Na finalnem snemanju je treba posneti vsaj deset različnih posnetkov tekačev pri teku. Zaradi zahtevnosti in obsega projekta smo realizirali le del analize teka, in sicer določanje stopnje pronacije s posnetka s hrbtne strani tekača. Vendar smo se v dobro nadaljnjih raziskav in razvoja odločili, da bomo poleg posnetkov, potrebnih za naše delo, hkrati zajemali tudi posnetke tekačev s strani. Zahteve, ki smo jih upoštevali pri zajemu posnetkov na snemanju, smo razdelili na tri sklope.

Zahteve s stališča analize teka

- Na posnetku od zadaj zajamemo tekača nekje do višine bokov, ker se pri takem zajemu najlažje določi kot v gležnju.

- Frekvenca zajema mora biti vsaj 100 Hz, saj v nasprotnem primeru lahko izgubimo ključne sličice.
- Paziti je treba, da tekač med snemanjem nima ohlapnih oblačil in je kontrasten z ozadjem (ima kratke hlače s čim krajšimi hlačnicami), saj ohlapna oblačila poslabšajo natančnost določanja skeleta tekača.
- Tekače snemamo med tekom v športnih copatih, ker nas zanima predvsem, kako deluje algoritem pri detekciji kota v gležnju med tekom v športnih copatih.
- Vse posnetke naredimo pri hitrosti teka 12 km/h, ki je dovolj visoka, da je pronacija izrazitejša, in hkrati dovolj nizka, da jo zmorejo vsi tekači vsaj za krajši čas.
- Za lažje računanje povprečij zajamemo vsaj 50 korakov teka vsakega tekača.
- Zajamemo vsaj deset različnih tekačev glede na stopnjo pronacije.
- Posnamemo lahko tudi istega tekača v različnih športnih copatih, saj se lahko kot v različnih copatih razlikuje, če so namenjeni supinatorjem, pronatorjem ali nevtralnim tekačem.

Zahteve s stališča računalniškega vida

- Ozadje pri snemanju mora biti relativno monotono in enotne barve, brez motečih elementov, saj to izboljša kvaliteto algoritma za detekcijo ospredja. Uporabi se črna zavesa.
- Treba je poskrbeti za čim večji kontrast med tekačem in ozadjem. Koža zagotavlja dovolj velik kontrast, kar izboljša detekcijo ospredja in natančnost določitve skeleta.
- Tekočem s temnejšimi športnimi copati se te prekrije z belim maskirnim trakom, z namenom zagotavljanja večjega kontrasta z ozadjem.

- Za potrebe algoritma za detekcijo ospredja je treba posneti tudi prazno sceno, torej samo stezo in ozadje. Posnetke se zajame tako, da se pri vsakem tekaču zajame najprej deset sekund kadra brez tekača, da se bo algoritem lahko naučil ozadja, nato pa še tek tekača brez premika ali ustavitve kamer, da se izognemo nezaželenim tresljajem in premikom kamer.

Zahteve s stališča zajema posnetkov

- Zagotoviti moramo dovolj svetlobe, ki omogoča zadostno odprtje zaslonke, da bodo posnetki dovolj ostri in osvetljeni (uporabi dodatnih reflektorjev se izognemo).
- Potrebujemo zadostno število kamer, najmanj dve, z ustrežno frekvenco zajema videoposnetkov in zadovoljivo ločljivostjo snemanja.
- Potrebujemo stativ in stojala za kamere, da dosežemo ustrezno postavitev kamere in s tem ustrezen zajem kadra.

Na finalnem snemanju smo posneli petnajst posnetkov, na katerih smo enega tekača snemali v dveh različnih parih športnih copat, v bolj stabilnih in manj stabilnih športnih copatih, ostale pa le enkrat v športnih copatih, ki jih običajno uporabljajo za tek. Torej smo skupaj posneli štirinajst različnih tekačev. Tekači so bili med seboj različni po starosti, spolu, teži in višini. Razlikovali so se tudi po načinu in tehniki teka ter po stopnji pronacije. Karakteristike tekačev glede na spol in stopnjo pronacije vidimo v tabeli 4.1. Tekače smo poimenovali z oznako, ki predstavlja prvo črko dneva snemanja (T ali C) in zaporedno številko posnetka. Snemali smo pet žensk in devet moških, od tega je bilo za levo nogo enajst tekačev nevtralnih, en pronator in trije supinatorji, za desno nogo pa dvanajst tekačev nevtralnih, en pronator in dva supinatorja. Tekači T4, T6, T8 in C3 so blizu meje za supinacijo, od tega je le zadnji označen kot supinator. Tekači T3, T7, C0 in C4 pa so blizu meje pronacije, od njih pa je le C4 označen kot pronator, ostali pa kot

nevtralni tekači. Tekake smo označili na podlagi ročno izmerjenega kota, in sicer, če je bil kot manjši kot 168° kot pronatorje, če je bil kot večji od 173° kot supinatorje in ostale kot nevtralne tekače.

Tekač	Spol	Leva	Desna
T2	M	nevtralen	nevtralen
T3	M	nevtralen	nevtralen
T4	M	supinator	nevtralen
T5	M	nevtralen	nevtralen
T6	M	supinator	supinator
T7	M	nevtralen	nevtralen
T8	Ž	nevtralen	nevtralen
T9	M	nevtralen	nevtralen
T10	Ž	nevtralen	nevtralen
T11	Ž	nevtralen	nevtralen
C0	M	nevtralen	nevtralen
C1	M	nevtralen	nevtralen
C2	M	nevtralen	nevtralen
C3	Ž	supinator	supinator
C4	Ž	pronator	pronator

Tabela 4.1: Posneti tekači glede na spol in stopnjo pronacije.


Snemali smo z dvema kamerama Panasonic Lumix FZ200. Ena kamera je bila postavljena za tekačem, druga pa na njegovi desni strani. Zadnja kamera je bila postavljena na oddaljenosti 481 cm od tekoče preproge, stranska kamera pa na oddaljenosti 343 cm od tekoče preproge. Obe kameri sta bili na višini 50 cm do spodnjega roba objektiva kamere, tako da sta bili postavljeni vzporedno s podlago. Postavitev kamer je vidna tudi na sliki 4.1.

Obe kameri sta zajemali videoposnetke pri ločljivosti 640×480 pik in pri frekvenci 200 Hz. Zadnja kamera je zajemala tekača do višine bokov (goriščnica objektiva približno 150 mm), stranska kamera pa približno do

sredine zgornjega dela telesa (goriščnica približno 100 mm). Vse tekače smo snemali pri enotni hitrosti teka 12 km/h. Pred vsakim tekačem smo najprej posneli vsaj deset sekund prazne scene, nato pa pri kontinuiranem snemanju posneli še tek tekača, da ne bi prišlo do morebitnih neželenih premikov kamere. Pri vsakem tekaču smo posneli vsaj 50 korakov teka pri polni hitrosti 12 km/h.

Snemanje je potekalo v dveh delih na dva različna dneva zaradi časovne razpoložljivosti tekačev, tako da se posnetki prvega in drugega dne malenkost razlikujejo po zajemu kadra in natančni poziciji kamere. Prvi dan snemanja smo posneli devet tekačev, od tega enega v različnih športnih copatih, torej skupno deset posnetkov. Drugi dan snemanja smo posneli pet tekačev. Tekači so bili večinoma pronatorji in nevtralni tekači, izrazitega supinatorja nam ni uspelo najti, saj so izraziti supinatorji med tekači dokaj redki. Skupini pronatorjev in supinatorjev pa sta precej majhni. Uspelo nam je pridobiti nekaj tekačev, ki imajo rahlo supinacijo.

Posnetke, ki smo jih pridobili na finalnem snemanju, smo razrezali in skrajšali tako, da so vsebovali na začetku 10 sekund (300 okvirjev) dolgo sekvenco prazne steze pri enaki hitrosti kot med tekom tekača, temu je sledil skrajšan posnetek teka tekača pri polni hitrosti 12 km/h, ki je vseboval vsaj dvajset polnih korakov teka (3500-4200 okvirjev), saj je to minimalno število korakov, ki jih je treba analizirati pri raziskavah teka v športu. Vsi posnetki so bili rezani tako, da se je tek tekača začel in končal, ko je bila desna noga v fazi opore.



Slika 4.1: Skica postavitve kamer na finalnem snemanju.

Poglavje 5

Rezultati in analiza

5.1 Ročno izmerjeni rezultati kota v gležnju

Rezultate vseh tekačev pridobimo z ročnim določanjem tako, da v vsakem koraku ročno izmerimo kot v gležnju takrat, ko je ta največji. Ročne meritve izvedemo s pomočjo brezplačnega programa Kinovea [26]. Za vsakega tekača tudi izračunamo povprečne vrednosti za vsako nogo ob upoštevanju najmanj dvajset korakov teka. Ti rezultati nam služijo kot referenca in z njimi primerjamo vse avtomatsko dobljene rezultate. Rezultati ročnih meritev skupaj s standardnimi odkloni so prikazani v tabeli 5.1.

5.2 Avtomatska analiza

Numerični rezultati zajemajo povprečne vrednosti preko vseh korakov za cel cikel ter povprečen kot leve in desne noge v fazi, ko je posamezna noga na tleh. Pridobimo jih za vse tri uporabljene metode. Prva metoda predstavlja avtomatsko zaznavanje kota v gležnju v kombinaciji z ročnim določanjem stika stopala s podlago, drugi dve pa avtomatsko zaznavanje kota v gležnju v kombinaciji z obema avtomatskima metodama določanja stika stopala s podlago. Rezultati metod so predstavljeni v tabeli 5.1. Pri tekaču T4 opazimo, da druga avtomatska metoda za detekcijo kota ne zazna pri levi nogi

Tekoč	Ročna metoda		1. avt. metoda		2. avt. metoda		3. avt. metoda	
	leva (st. odk.)	desna (st. odk.)	leva	desna	leva	desna	leva	desna
T2	169,05 (0,95)	169,91 (1,02)	162,5134	164,6532	165,5814	168,0157	162,1678	162,5977
T3	168,05 (1,27)	168,65 (1,42)	168,9750	171,2663	168,4275	170,5942	167,1905	169,7071
T4	173,9 (1,29)	172,25 (1,16)	172,9666	172,5550	NaN	172,7906	173,1177	170,7491
T5	171,38 (1,16)	170,1 (1,18)	174,5465	172,6079	172,5395	170,3015	171,7663	168,3224
T6	174,1 (0,89)	173,95 (0,80)	175,8307	175,1275	175,7661	174,5028	176,0126	173,4484
T7	169,62 (1,24)	168,52 (1,56)	169,0986	171,9245	167,0967	170,8467	164,7303	170,4589
T8	172,64 (0,79)	172,83 (0,71)	172,0700	170,0856	171,2825	169,0736	170,8690	169,5958
T9	172,76 (0,83)	172,27 (0,76)	171,5985	169,4863	172,2843	172,1523	172,4460	172,4328
T10	172,23 (0,81)	170,95 (0,84)	170,0386	171,2111	172,5102	171,5503	169,9777	171,1938
T11	171,14 (0,85)	170,67 (1,15)	173,8483	171,2535	174,6428	171,9128	172,8044	172,4612
C0	170,95 (0,86)	170,33 (0,85)	167,7573	169,1199	167,1159	167,4022	166,4035	167,3779
C1	172,14 (1,23)	171,52 (0,68)	171,5392	166,9197	171,0868	166,6605	171,4064	165,9348
C2	171,2 (1,05)	170,65 (0,93)	170,3599	168,9741	170,0259	168,7353	170,7323	169,8883
C3	174,52 (0,60)	174,05 (0,92)	172,9355	171,5161	173,3502	172,9852	172,3697	171,3247
C4	166,68 (1,08)	167,36 (1,21)	164,8968	168,4224	165,8908	169,5576	165,2582	167,2528

Tabela 5.1: Rezultati meritev kota v gležnju tekačev.

nobenega intervala kjer je noga v stiku s podlago, zato je tu v tabeli zapisana vrednost NaN. Do tega pride zaradi napak pri zaznavi točke gležnja, saj so vse povprečne vrednosti točke gležnja obeh nog znotraj intervala. Tako zaznamo, da sta obe nogi na tleh hkrati preko celega cikla. Zato upoštevamo le eno, pri drugi pa takih točk ni. Upoštevali bi lahko tudi povprečje kota preko celega cikla za obe nogi, vendar uporaba oznake NaN opozarja na to, da vrednosti niso natančne.

Vse tri sklope dobljenih rezultatov avtomatskega merjenja kota v gležnju nato primerjamo z ročno izmerjenimi vrednostmi. Za vsakega tekača izračunamo absolutno in relativno napako v primerjavi z ročnim povprečjem kota. Absolutno napako računamo po formuli

$$\text{abs}_i = V_i - R_i, \quad (5.1)$$

kjer je V_i vrednost, pridobljena s pomočjo avtomatske izmere kota v gležnju i-tega tekača, R_i pa pripadajoča ročno izmerjena povprečna vrednost. Relativno napako za posameznega tekača računamo po formuli

$$\text{rel}_i = \frac{|V_i - R_i|}{R_i}. \quad (5.2)$$

Napake so pri vseh treh metodah podane najprej po posameznih dnevih snemanja, nato pa še skupaj, tako za vsako nogo posebej kot tudi za obe skupaj.

V tabeli 5.2 vidimo relativne in absolutne napake avtomatske analize, ki uporablja prvo metodo določanja stika stopala s podlago, torej ročno določanje stika stopala s podlago.

V tabeli 5.3 so predstavljene relativne in absolutne napake avtomatske analize, ki uporablja drugo metodo določanja stika stopala s podlago. Ta metoda pri enem od tekačev ni našla nobenega intervala, kjer bi bilo po uporabljenih kriterijih stopalo v stiku s podlago.

V tabeli 5.4 so predstavljene relativne in absolutne napake avtomatske analize, ki uporablja tretjo metodo določanja stika stopala s podlago.

Snemanje	abs. nap. L	abs. nap. D	rel. nap. L	rel. nap. D	rel. nap. obeh nog skupaj
1. dan	2,387363	2,16387	0,0138712	0,012691	0,013281
2. dan	1,60244	2,21674	0,0093828	0,012932	0,011157
Skupaj	1,994902	2,190305	0,011627	0,012811	0,012219

Tabela 5.2: Povprečne vrednosti napak prve metode po posameznih dnevih in skupaj.


Snemanje	abs. nap. L	abs. nap. D	rel. nap. L	rel. nap. D	rel. nap. obeh nog skupaj
1. dan	2,027281	1,317529	0,011799	0,007718	0,009758
2. dan	1,606262	2,593104	0,009381	0,015199	0,012290
Skupaj	1,816772	1,955317	0,01059	0,011459	0,011024

Tabela 5.3: Povprečne vrednosti napak druge metode po posameznih dnevih in skupaj.

Na grafu 5.1 vidimo še grafično predstavitev relativnih napak vseh treh metod skupaj v odstotkih.

Snemanje	abs. nap. L	abs. nap. D	rel. nap. L	rel. nap. D	rel. nap. obeh nog skupaj
1. dan	2,514311	1,950279	0,014634	0,011433	0,013033
2. dan	1,86618	2,427976	0,010901	0,014141	0,012520
Skupaj	2,190246	2,189128	0,012767	0,012787	0,012777

Tabela 5.4: Povprečne vrednosti napak tretje metode po posameznih dnevih in skupaj.



Slika 5.1: Graf relativnih napak vrednosti kota posamezne noge in skupaj za vse tri metode.

5.3 Klasifikacija tekačev in napačne klasifikacije

Na podlagi izmerjenih vrednosti nato tekače klasificiramo v tri skupine. Prva skupina so tekači s prekomerno stopnjo pronacije. Vanjo klasificiramo vse tekače, katerih povprečen izmerjen kot je manjši ali enak 168° . Druga sku-

pina so tekači, ki imajo premajhno stopnjo pronacije, torej supinatorji. V to skupino klasificiramo vse tekače, ki so imeli izmerjen kot večji ali enak 173° . Vse tekače, ki imajo izmerjene vrednosti kotov med obema vrednostma, klasificiramo kot nevtralne tekače. Meje za klasifikacijo prekomerne pronacije in supinacije se na splošno precej razlikujejo in niso natančno določene, saj jih je težko ugotoviti, zato smo se pri našem delu odločili, da za lažjo klasifikacijo postavimo meje na 168° za pronacijo in 173° za supinacijo [27].

Po ročno izmerjenih vrednostih je za levo nogo enajst tekačev klasificiranih kot nevtralnih, en kot pronator in trije kot supinatorji. Za desno nogo je na podlagi ročno izmerjenih vrednosti dvanajst tekačev klasificiranih kot nevtralnih, en kot pronator in dva kot supinatorja. Od tega sta za levo nogo dva tekača v okolici 1° od izbrane meje za pronacijo in sedem tekačev v okolici 1° izbrane meje za supinacijo. Pri desni nogi so v okolici 1° okoli meje za pronacijo trije tekači in okoli meje za supinacijo pet tekačev.

Prva metoda avtomatske analize je narobe klasificirala pet tekačev za levo nogo in štiri tekače za desno. Torej je bila uspešnost metode za pravilno klasifikacijo leve noge 67 %, za pravilno klasifikacijo desne noge pa 73 % (tabela 5.5). Glede na stopnjo pronacije je bila prva metoda v 50 % uspešna pri klasifikaciji pronatorjev, 78 % uspešna pri klasifikaciji nevtralnih tekačev in 40 % uspešna pri klasifikaciji supinatorjev, kar prikazuje tudi graf 5.3. Pri računanju uspešnosti po razredih tekačev smo za pravilno klasifikacijo uporabili ročno klasifikacijo. Uspešnost pa smo izračunali tako, da smo dobili odstotek pravilno klasificiranih nog znotraj posamezne skupine, glede na ročno klasifikacijo.


Druga metoda avtomatske analize je levo nogo napačno klasificirala petim tekačem, desno nogo pa štirim. Tako je tudi uspešnost pravilne klasifikacije te metode 67 % za levo nogo in 73 % za desno nogo (tabela 5.5). Glede na stopnjo pronacije je bila druga metoda v 50 % uspešna pri klasifikaciji pronatorjev, 74 % uspešna pri klasifikaciji nevtralnih tekačev in 60 % uspešna pri klasifikaciji supinatorjev, kar prikazuje tudi graf 5.3.

Tretja metoda avtomatske analize je za levo in desno nogo napačno klasi-


ficirala pet tekačev. Tako je bila uspešnost te metode za pravilno klasifikacijo tako desne kot leve noge 67 % (tabela 5.5). Glede na stopnjo pronacije je bila tretja metoda 100 % uspešna pri klasifikaciji pronatorjev, v 70 % uspešna pri klasifikaciji nevtralnih tekačev in 40 % uspešna pri klasifikaciji supinatorjev, kar prikazuje tudi graf 5.3.

	leva noga	desna noga	obe nogi skupaj
1. metoda	67 %	73 %	70 %
2. metoda	67 %	73 %	70 %
3. metoda	67 %	67 %	67 %

Tabela 5.5: Uspešnost pravilne klasifikacije vseh treh metod za vsako nogo in skupaj.



Slika 5.2: Graf uspešnosti klasifikacije posamezne noge in skupaj za vse tri metode.




Slika 5.3: Graf uspešnosti klasifikacije obeh nog skupaj po posameznih razredih za vse tri metode.

5.4 Diskusija

Rezultati vseh treh avtomatskih metod so zelo podobni, čeprav uporabljajo različne načine določitve faze stika stopala s podlago (slika 5.1). Obe avtomatski metodi določitve stika s podlago dajeta nenatančne rezultate v primerjavi z ročnim določanjem.

Druga metoda, ki določa stik s podlago na podlagi intervala, v katerem mora biti višina točke gležnja, za večino tekačev določi skoraj polovico cikla za posamezno nogo, kar je pri hitrosti teka, pri kateri so tekli sodelujoči v eksperimentu, občutno preveč. Povprečje ročno izmerjenih vrednosti je le okoli 12 % celega cikla za vsako nogo. Vendar so rezultati zaradi vseh povprečnih vrednosti preko vseh ciklov in povprečnih vrednosti preko cele faze stika noge s podlago zelo podobni rezultatom metode, ki uporablja ročno določanje faze stika s podlago. Povprečna napaka te metode se celo izkaže



Slika 5.4: Graf uspešnosti klasifikacije tekačev, ki niso na meji med razredi, za vse tri metode.

za najmanjšo (slika 5.1). Vzrok za to je tudi dejstvo, da se zaznan kot v gležnju zunaj faze opore zaradi napak v zaznavi ne razlikuje veliko od kota, izmerjenega v fazi opore. Zato napake pri zaznavi faze opore ne vplivajo veliko na povprečne vrednosti kota. Pri tej metodi se tudi izkaže, da pri enem tekaču zaradi napak in šuma v podatkih ne zaznamo nobene točke znotraj intervala, ki smo ga določili, tako da se v tem primeru metoda izkaže za neuporabno.

Tretja metoda določanja faze stika stopala s podlago ravno tako daje netočne rezultate. Pri tej metodi so sicer deleži faze opore za vsako nogo razmeroma pravilni, saj jih določimo ročno na podlagi povprečne dolžine faze opore posamezne noge. Vendar so intervali, ko naj bi bila noga na tleh, v primerjavi z ročno izmerjenimi zamaknjeni naprej ali nazaj od dejanskih intervalov. Metoda torej zazna, da se faza opore začne, preden se noga

dejansko dotakne tal, ali pa zazna fazo opore še v času, ko se noga že dviga od podlage in je že v fazi odriva. Pri nekaterih tekačih so intervali določeni popolnoma napačno. In sicer predvsem pri tekačih, pri katerih se zaznani cikli pri obdelavi signalov začnejo na sredini stika s podlago ene izmed nog in je zato interval faze opore za to nogo razdeljen na začetek in na konec cikla. Vendar tudi ta metoda zaradi istih razlogov kot prejšnja da podobne rezultate kot tista, ki uporablja ročno določene vrednosti.

Vse tri metode dajejo za grobo klasifikacijo tekačev glede pronacije zadovoljive rezultate (slika 5.2), problem je pri mejnih vrednostih, kjer je v kombinaciji z ročnim pregledom rezultatov dosežena pravilna klasifikacija pri večini metod in lahko s tem dosežemo optimalno ročno klasifikacijo. Pri pravilnosti klasifikacije sta boljši prva in druga metoda, tretja pa ima malenkost slabšo klasifikacijo, vendar pa bi te rezultate verjetno izboljšali pri večji bazi tekačev. Pri določenih tekačih, kjer je dobra detekcija silhuete in malo samoprekrivanja nog tekača, je absolutna napaka manj kot 1° . Pri posnetkih, kjer je slaba detekcija silhuete, kjer ima ta v spodnjem delu pri stopalu še precej lukenj in tekač precej prekriva noge pri teku, kot recimo pri posnetku C0, pa je napaka velika, povprečna absolutna napaka znaša $3,22^\circ$, povprečna relativna napaka pa 1,82 %. Tako da lahko tudi tukaj z vizualnim pregledom posnetka, ki je del rezultata, v grobem ocenimo, ali je rezultat dokaj zanesljiv ali pa ima precej napak in šuma v podatkih ter je zato nenatančen. Odstotek pravilno klasificiranih bi verjetno izboljšali pri testiranju večjega števila tekačev ob predpostavki, da so tekači naključno in enakomerno razporejeni glede na stopnjo pronacije in niso vsi ravno na mejah klasifikacijskih skupin.

Mislimo, da je takšna detekcija delno uporabna za grobo detekcijo pronatorjev in supinatorjev. Pri mejnih vrednostih je potreben še vizualen pregled posnetka rezultata za natančno določitev. Pri tekačih, ki niso na meji, pa je detekcija precej uspešna, kot je razvidno iz grafa 5.4. Tekočev, ki niso na meji, je za levo nogo devet, od tega sedem nevtralnih, en pronator in en supinator. Za desno nogo pa je takih tekačev šest in so vsi nevtralni. Pri tem smo upoštevali tekače, ki imajo ročno izmerjene vrednosti za več kot eno stopinjo

oddaljene od izbranih mej za posamezne razrede. Za raziskave v športu je metoda določanja kota v gležnju v trenutni obliki premalo natančna, saj je dobro, da kot določa vsaj na stopinjo natančno ali še manj. Torej je za ta namen treba narediti še nekaj uspešnih izboljšav natančnosti.

Za izboljšanje natančnosti detekcije je treba predvsem izboljšati natančnost detekcije silhuete. Ta se verjetno tudi izboljša, če je program del neke fiksne naprave, ki vključuje tekočo preprogo in fiksno vgrajene kamere, tako da se videoposnetek resnično zajema pri enakih pogojih. Menimo, da prihaja do razlik v posnetkih tudi zaradi samega zaznavanja kamere, saj zaradi različnih barv kože tekačev, njihovih oblačil in obutve različno zajame posnetke zaradi prilagajanja nastavitve beline in spremembe v osvetlitvi. Zaznavo silhuete je mogoče izboljšati tudi z bolj prilagojenimi posnetki, ki omogočajo večji kontrast med tekačem in ozadjem in tudi posameznimi deli tekača. Možna izboljšava je tudi bolj prilagojen nabor parametrov zaznave ospredja ali predhodna obdelava posnetkov, tako da se jim po potrebi poveča kontrast, popravi zaznavo barve kamere in podobno. Z boljšo detekcijo silhuete se izboljša tudi detekcija ključnih točk sklepov.

Nekaj manevrskega prostora pa dopušča tudi izboljšava natančnosti določanja točk sklepov. Predvsem natančnost določanja točke kolena, ki se v našem primeru sploh ne določa, ampak se uporabi kar sredinsko točko čim višje na spodnjem delu noge ter detekcijo spodnje točke športnega copata, katere natančna določitev je problematična zaradi sence tekača na tleh. Vsak odmik levo ali desno katerekoli od teh dveh točk in točke gležnja hitro privede do napake nekaj stopinj pri kotu v gležnju. Izboljšavo določanja točk sklepov lahko dosežemo tudi z dodatno uporabo znanih biometričnih lastnosti človeka, kot je na primer razmerje med dolžino delov posameznih okončin in višino človeka.

Dodatno lahko rezultate izboljšamo tudi z analizo večjega števila ciklov tekača pri teku, torej več korakov teka, vendar je analiza dolgih posnetkov precej dolgotrajna in časovno zahtevna. Večje število zaznanih podatkov izboljša natančnost povprečij in bolj izniči vplive napak pri zaznavanju.


Prav tako je treba algoritme preizkusiti na večjem številu posnetkov različnih tekačev.

Rezultate lahko dodatno izboljšamo tudi z izboljšavo algoritmov za zaznavanje faze stika stopala s podlago. Pri tem bi si lahko pomagali tudi s posnetkom tekača od strani, saj je tako lažje določiti točko stika stopala s podlago. Prav tako je mogoče, da se z zmanjšanjem šuma in napak v zaznavi silhuete tekača in z izboljšavo natančnosti zaznave sklepov in ostalih ključnih točk pokažejo kakšne nove lastnosti in zakonitosti med podatki, ki bi pripomogle k lažji zaznavi faze opore.

Smiselno bi bilo razviti tudi prototipe algoritmov za preostanek analize teka, algoritme, ki analizirajo posnetke tekača od strani in posnetke od spredaj. Algoritme, ki na posnetku tekača s strani ugotavljajo kote v gležnju, kolenu in kolku, ki detektirajo, kdaj in s katerim delom stopala se tekač najprej dotakne podlage. S pomočjo teh lahko ugotavljamo, kako pokončna je drža zgornjega dela telesa, pot kolena skozi fazo opore, torej po kakšni poti v fazi opore potuje koleno preko gležnja, in ali sta v fazi opore koleno in gleženj poravnana drug nad drugim. Za te nadaljnje raziskave smo delno pripravili osnovo s tem diplomskim delom. Pri zajemanju posnetkov s hrbtne strani tekača smo hkrati zajeli tudi posnetke z desne strani, tako da so ti posnetki petnajstih tekačev na voljo za nadaljnjo obdelavo. Posnetki s sprednje strani tekača pa so na voljo le s poizkusnega snemanja.

Ne nazadnje je mogoča tudi uporaba polavtomatskih metod z uporabo markerjev.

Sama metoda določanja kota v gležnju je torej v trenutni obliki precej občutljiva na različne tekače in različne okoliščine snemanja, tako da metoda ni prav robustna. Potrebni so kontrolirani pogoji snemanja. Pri raznolikosti tekačev se za največji problem izkaže samoprekrivanje nog pri posameznih tekačih, kot je razvidno na sliki 5.5, saj se v tem primeru nogi v silueti zlijeta v eno in ju ni mogoče zaznati ločeno. Zaradi tega je računanje sredinskih točk oteženo in jih je praktično nemogoče natančno izračunati.



Slika 5.5: Primer, ko tekač med tekom z eno nogo delno prekrije drugo.

Poglavje 6

Sklepne ugotovitve

V tem diplomskem delu smo torej predlagali prototip algoritma za avtomatsko detekcijo kota v gležnju pri tekačih med tekom. Posneli smo štirinajst različnih tekačev med tekom in s tem pridobili petnajst različnih posnetkov, na katerih smo nato preizkusili naše algoritme. Razvili smo algoritme, ki s posnetka tekača s hrbtne strani brez dodatnih pomagal in osvetlitve zaznajo kot v gležnju med fazo opore. Algoritmi podajo rezultat v obliki povprečnega kota v gležnju za vsako nogo. Poleg tega je rezultat predstavljen tudi vizualno kot sekvenca slik, kjer ima tekač na nogah označene ključne točke in izmerjen kot. Dobljene rezultate smo nato analizirali in primerjali z ročno pridobljenimi meritvami.

Predlagane metode za določanje kota v gležnju pri tekačih med tekom imajo zaenkrat zadovoljive rezultate, vendar ne za raziskave v športu. Najmanjša relativna napaka je manj kot 1 %, vendar je to za uporabo pri raziskavah v športu premalo natančno, saj je dobro, če napaka znaša okoli 0,5 %. Klasifikacija tekačev je uspešna pri tekačih, ki niso blizu mej različnih stopenj pronacije. Pri tekačih, ki so na meji, imajo predlagani algoritmi več napak v klasifikaciji, ki so posledice prevelikih napak pri določanju kota in majhne tolerance napak na meji med posameznimi stopnjami pronacije.

V bodoče je zato treba izboljšati natančnost metode za avtomatsko določanje kota v gležnju, tako da napaka ne bo večja od 1° in bo metoda primerna

tudi za raziskave v športu. Zato je najprej treba ugotoviti, ali so obstoječi posnetki dovolj dobri ali pa so za to potrebni boljši in bolj prilagojeni posnetki. Nadalje je mogoče izboljšati detekcijo silhuete tekača. Dodatno lahko razvijemo boljše in natančnejše avtomatske metode za zaznavanje stika stopala s podlago, če se zaznavanje tega ne izboljša že z natančnejšo detekcijo ključnih točk, predvsem točke gležnja. Prav tako je mogoče nadaljnje delo v smeri razvoja podobnih algoritmov za preostale dele analize teka, torej algoritmov, ki analizirajo posnetke tekača s sprednje in leve ali desne strani.

Metoda avtomatske analize tekača je torej še delna in premalo natančna za splošnejšo uporabo, vendar so začetni rezultati zadovoljivi in toliko obetavni, da je v nadaljnjih raziskavah mogoče razviti izboljšane aplikacije, ki lahko blizu realnega časa avtomatsko izvedejo skoraj popolno analizo tehnike tekača s posnetkov. Torej sta razvoj in nadaljnje delo v tej smeri smiselna. Taka aplikacija ima tako velik ekonomski potencial v splošni populaciji in športnih trgovinah kot tudi kot orodje za pomoč in hitrejše raziskave na področju teka v športu.

Slike

1.1	Prikaz vseh podfaz teka [3].	2
1.2	Prikaz pronacije, supinacije in nevtralnega položaja desne noge [6].	4
2.1	Pogled na tekača s sprednje strani, kjer vidimo pot kolena preko stopala.	7
3.1	Diagram poteka rešitve.	14
3.2	Rezultat detekcije ospredja.	17
3.3	Silhueta tekača po izvedbi morfoloških operacij.	20
3.4	Primer izrisanih segmentov tekača, sredinskih točk po segmentih in pridobljenih premic.	24
3.5	Označen kot, ki nas zanima.	27
3.6	Primer rezultata obdelave: posnetek tekača z označenimi daljicami in točkami na nogah ter izpisanimi koti za vsako nogo.	29
3.7	Grafi posameznih opazovanih spremenljivk v ciklu tekača.	32
4.1	Skica postavitve kamer na finalnem snemanju.	41
5.1	Graf relativnih napak vrednosti kota posamezne noge in skupaj za vse tri metode.	46
5.2	Graf uspešnosti klasifikacije posamezne noge in skupaj za vse tri metode.	48
5.3	Graf uspešnosti klasifikacije obeh nog skupaj po posameznih razredih za vse tri metode.	49

-
- 5.4 Graf uspešnosti klasifikacije tekačev, ki niso na meji med razredi, za vse tri metode. 50
- 5.5 Primer, ko tekač med tekom z eno nogo delno prekrije drugo. . 54

Tabele

4.1	Posneti tekači glede na spol in stopnjo pronacije.	39
5.1	Rezultati meritev kota v gležnju tekačev.	44
5.2	Povprečne vrednosti napak prve metode po posameznih dne- vih in skupaj.	45
5.3	Povprečne vrednosti napak druge metode po posameznih dne- vih in skupaj.	45
5.4	Povprečne vrednosti napak tretje metode po posameznih dne- vih in skupaj.	46
5.5	Uspešnost pravilne klasifikacije vseh treh metod za vsako nogo in skupaj.	48

Literatura

- [1] H. Steffny. *Velika tekaška knjiga*. Založba Sanje, 1. edition, 2013.
- [2] U. Horvat. Tek z največjo hitrostjo po različnih nakloninah. Master's thesis, Fakulteta za šport Univerze v Ljubljani, 2008.
- [3] Acute hamstring injuries. Dostopno na: <http://sportinjuryperformance.files.wordpress.com/2013/02/running-gait.jpg>, 2013.
- [4] M. Čoh, ur. *Biomehanika atletike*. Fakulteta za šport, 2001.
- [5] U. Praprotnik, et al. *Tekaški trener*. Palestra, 1. edition, 2006.
- [6] J. Stoxen. What is foot pronation and foot supination? is it good or bad? Dostopno na: http://teamdoctorsblog.com/wp-content/uploads/2012/03/Safe_Range.jpg, 2012.
- [7] P. Vigneron. Your running shoes don't matter. Dostopno na: <http://www.outsideonline.com/fitness/bodywork/in-stride/Your-Running-Shoes-Dont-Matter.html>, december 2013.
- [8] B. De Wir, D. De Clercq, M. Lenoir. The effect of Varying Midsole Hardness on Impact Forces and Foot Motion During Foot Contact in Runnig. *Journal of Applied Biomechanics*, 11: p.p. 395 – 406, 1995.
- [9] B. Van Gheluwe, R. Tielemans, P. Roosen. The Influence of Heel Counter Rigidity on Rearfoot Motion During Running. *Journal of Applied Biomechanics*, 11: p.p. 47 – 67, 1995.

-
- [10] R. Ferrandis, A. Garcia, J. Ramiro, Ju.r Hoyos, P.Vera. Rearfoor Motion and Torsion in Running: The Effects of Upper Vamp Stabilizers. *Journal of Applied Biomechanics*, 10: p.p. 28 – 42, 1994.
- [11] B. Van Gheluwe, C. Madsen. Frontal Rearfoot Kinematics in Running Prior to Volitional Exhaustion. *Journal of Applied Biomechanics*, 13: p.p. 66 – 75, 1997.
- [12] A. T. Delo, T. A. Dierks, R. Ferber, I. S. Davis. Lower extremity joint coupling during running: a current update. *Clinical Biomechanics*, 19: p.p. 983 – 991, 2004.
- [13] J. Yoo, M. S. Nixon. Automated Markerless Analysis of Human Gait Motion for Recognition and Classification. *ETRI Journal*, 33: p.p. 259 – 266, april 2011.
- [14] G. Bradski, A. Kaehler. *Learning OpenCV*. O'Reilly Media, 2008.
- [15] Matlab documetation: vision.ForegroundDetector System object, Detects foreground using Gaussian mixture models. Dostopno na: http://www.mathworks.com/help/vision/ref/vision_foregrounddetectorclass.html.
- [16] R. Laganière. *OpenCV 2 Computer Vision Application Programming Cookbook*. Packt Publishing, maj 2011.
- [17] R. Bowden P. KaewTraKulPong. An Improved Adaptive Background Mixture Model for Realtime Tracking with Shadow Detection. *In Proc. 2nd European Workshop on Advanced Video Based Surveillance Systems, AVBS01*, september 2001.
- [18] W.E.L Grimson C. Stauffer. Adaptive Background Mixture Models for Real-Time Tracking. *IEEE Computer Society Conference*, 2: p.p. 246 – 252, 1999.

-
- [19] Matlab documentnation: bwmorph, morphological operations on binary images. Dostopno na: <http://www.mathworks.com/help/images/ref/bwmorph.html>.
- [20] Matlab documentation: imdilate, dilate image. Dostopno na: <http://www.mathworks.com/help/images/ref/imdilate.html>.
- [21] Matlab documentation: bwareaopen, remove small objects from binary image. Dostopno na: <http://www.mathworks.com/help/images/ref/bwareaopen.html>.
- [22] Matlab documentation: bwboundaries, trace region boundaries in binary image. Dostopno na: <http://www.mathworks.com/help/images/ref/bwboundaries.html>.
- [23] P. E. Hart R. O. Duda. Use od The Hough Transformation to Detect Lines and Curves in Pictures. *Comm. ACM*, 15: p.p. 11 – 15, januar 1972.
- [24] P. Peer J. Kovač. Human Skeleton Model Based Dynamic Features for Walking Speed Invariant Gait Recognition. *Mathematical Problems in Engineering*, 2014, januar 2014.
- [25] A. Kusuma. Analysis of Runner Biomechanics Through Image Processing. Technical report, TJHSST Computer Systems Lab, junij 2008.
- [26] Kinovea - a microscope for your videos. Dostopno na: <http://www.kinovea.org/>, 2014.
- [27] K. Maggs. The definitive guide to pronation: Clinicians version. Dostopno na: <http://runningreform.com/the-definitive-guide-to-pronation-clinicians-version/>, februar 2013.